

UNIVERSIDADE DE LISBOA
FACULDADE DE CIÊNCIAS
DEPARTAMENTO DE ESTATÍSTICA E INVESTIGAÇÃO OPERACIONAL



Análise de Tendências de Evolução dos Padrões de Mobilidade na Região do Algarve

Susana Maria Miranda da Silva

Mestrado em Estatística e Investigação Operacional
Especialização em Estatística

Trabalho de Projeto orientado por:
Professora Doutora Helena Iglésias Pereira
Doutora Engenheira Elisabete M. M. Arsénio Guterres De Almeida

Agradecimentos

A concretização deste projeto teve o contributo de um conjunto de pessoas que foram indispensáveis na realização do mesmo.

Em primeiro lugar um especial agradecimento à professora Helena Iglésias por ter sido essencial no desenvolvimento desde projeto, não só pelo seu suporte constante e transmissão de conhecimentos, mas principalmente pela sua disponibilidade e preocupação demonstrada ao longo de todo este percurso.

À Sra. Doutora Engenheira Elisabete Arsénio, investigadora do Laboratório Nacional de Engenharia Civil (LNEC) pela proposta do presente tema de projeto à Faculdade de Ciências/MEIO em cooperação com a CCDR Algarve e AMAL, pela sua colaboração e disponibilidade.

Ao Dr. Alexandre Domingues, representante da CCDR Algarve, e ao Arquiteto Jorge Coelho, representante da AMAL, pelas deslocações a Lisboa e por todos os comentários e sugestões relativos aos transportes do Algarve que me permitiram enriquecer o conteúdo do projeto.

Agradeço também ao professor António José Rodrigues por se ter mostrado disponível e pronto para ajudar na fase final do projeto.

Resumo

A região do Algarve é conhecida como uma das mais requisitadas zonas turísticas da Europa devido ao seu clima temperado mediterrâneo e às praias e paisagens naturais que despertam a atenção de muitos turistas nacionais e estrangeiros. Este reconhecimento tem vindo a aumentar, fazendo com que o turismo tenha vindo a crescer gradualmente ao longo dos anos. Para tentar acompanhar esta tendência de evolução, os serviços de transporte têm sofrido algumas alterações, no entanto ainda se verifica a utilização do transporte individual como principal meio de deslocação, o que não contribui para o conceito de mobilidade sustentável da região.

Neste projeto é analisada a evolução do movimento de passageiros no transporte aéreo, marítimo-fluvial e transporte coletivo rodoviário e ferroviário, a evolução do Tráfego Médio Diário (TMD) na rede rodoviária principal, designadamente nos itinerários principais do Algarve e ainda a evolução do número de utilizadores de bicicleta na região do Algarve.

Para realizar a previsão de cada uma das séries temporais, recorreu-se ao *software* R, e foram utilizados os modelos autorregressivos integrados e de médias móveis para séries com sazonalidade. A metodologia utilizada baseia-se essencialmente na metodologia de Box & Jenkins (1970) para a previsão de séries temporais, que se centra principalmente na análise gráfica da série temporal em estudo, estimação dos parâmetros do modelo, diagnóstico do modelo e na previsão dos valores futuros.

Prevê-se que os resultados do projeto sejam úteis para apoiar o desenvolvimento de políticas públicas visando a mobilidade sustentável na região, designadamente para inverter possíveis tendências na utilização dominante do transporte individual e promover uma maior utilização do transporte coletivo, de novos serviços de mobilidade hipocarbónicos e incrementar a utilização de modos suaves de transporte como a bicicleta.

Palavras-chave:

Transportes; Algarve; Mobilidade Sustentável; Séries Temporais; Previsão; Modelos SARIMA.

Abstract

The Algarve region is known as one of the most sought-after tourist areas in Europe due to its temperate Mediterranean climate, beaches and natural landscapes that attract the attention of many domestic and foreign tourists. This recognition has been increasing, causing tourism to gradually grow over the years. To try to keep up with this trend of evolution, transport services have undergone some changes, however, individual transport is still used as the main means of travel, which does not contribute to the concept of sustainable mobility in the region.

This project analyzes the evolution of the movement of passengers in air, rail, sea-river and road transport, the evolution of the Average Daily Traffic on the main roads of Algarve and the evolution of the number of bicycle users in the Algarve region.

To perform the forecast of each of the time series the software R was used along with the autoregressive integrated moving average models for series with seasonality. The methodology used is essentially based on Box & Jenkins (1970) methodology for the forecast of time series, which focuses mainly on the graphical analysis of the time series being studied, the estimation of model parameters, the identification of the model and on the forecast of future values.

The results of the project are expected to be useful in supporting the development of public policies aimed at sustainable mobility, more specifically, to reverse possible trends in the dominant use of individual transport and to promote greater use of collective transportation, new low-carbon mobility services and increase the use of soft transport solutions such as bicycles.

Keywords:

Transportation; Algarve; Sustainable Mobility; Time Series; Forecast; SARIMA models.

Índice

Agradecimentos	i
Resumo	ii
Abstract	iii
Lista de Figuras	vi
Lista de Tabelas	xi
Lista de Abreviaturas.....	xii
1. Introdução.....	1
1.1. Enquadramento.....	1
1.2. Objetivos	3
1.3. Metodologia	3
1.4. Estrutura do Relatório de Projeto	4
2. Análise e Previsão de Séries Temporais	5
2.1. Conceitos Básicos	5
2.2. Elementos para a Previsão	6
2.2.1. Transformação de Box-Cox	6
2.2.2. Estacionariedade.....	6
2.2.3. Função de Autocorrelação.....	7
2.2.4. Função de Autocorrelação Parcial.....	8
3. Modelação	9
3.1. Modelos de Séries Temporais	9
3.1.1. Modelo Autorregressivo.....	9
3.1.2. Modelo de Médias Móveis	10
3.1.3. Modelo Autorregressivo e de Médias Móveis	11
3.1.4. Modelo Autorregressivo Integrado de Médias Móveis	11
3.1.5. Modelo Autorregressivo Integrado de Médias Móveis Sazonal	12
3.2. Seleção do Modelo de Previsão.....	12
3.2.1. Critério de Informação de <i>Akaike</i>	12
3.3. Diagnóstico do Modelo de Previsão.....	13

4. Estimação dos Modelos e Análise de Resultados	15
4.1. Transporte Aéreo	15
4.1.1. Movimento de Passageiros no Aeroporto Internacional de Faro	15
4.1.2. Movimento de Passageiros entre o Aeroporto Internacional de Faro e Aeroportos Nacionais	20
4.2. Transporte Coletivo Ferroviário	25
4.2.1. Movimento de Passageiros no Serviço Regional	25
4.2.2. Movimento de Passageiros no Serviço de Longo Curso	28
4.3. Transporte Fluvial/Marítimo	32
4.3.1. Movimento de Passageiros no Guadiana (Vila Real de Santo António – Ayamonte)	32
4.3.2. Movimento de Passageiros na Ria Formosa.....	35
4.4. Transporte Coletivo Rodoviário	36
4.4.1. Movimento de Passageiros nas Ligações Urbanas	36
4.4.2. Movimento de Passageiros nas Ligações Inter-Urbanas	40
4.4.3. Movimento de Passageiros nas Ligações Inter-Regionais	43
4.4.4. Movimento de Passageiros nas Ligações Internacionais.....	46
4.5. Transporte Rodoviário na Rede Rodoviária Principal.....	49
4.5.1. Tráfego Médio Diário na Autoestrada A2 (Almodôvar/São Bartolomeu de Messines)	49
4.5.2. Tráfego Médio Diário na Ponte Internacional do Guadiana	53
4.5.3. Tráfego Médio Diário na Autoestrada A22.....	57
4.6. A Bicicleta como modo de Transporte Hipocarbónico e Saudável.....	60
5. Conclusão e Recomendações	65
Referências Bibliográficas	69
Apêndices	72
Apêndice A: Previsões das séries temporais do Transporte Aéreo	72
Apêndice B: Previsões das séries temporais do Transporte Ferroviário	72
Apêndice C: Previsões das séries temporais do Transporte fluvial/Marítimo	73
Apêndice D: Previsões das séries temporais do Transporte Coletivo/Rodoviário	73
Apêndice E: Previsões das séries temporais do Transporte rodoviário: Eixos Principais	74

Lista de Figuras

Figura 1.1: Modo de transporte utilizado nos movimentos pendulares (%)	2
Figura 4.1: Movimento de Passageiros no Aeroporto Internacional de Faro de 2007 a 2017: (a) Observações trimestrais; (b) Observações anuais	15
Figura 4.2: Diferenciação da série do Movimento de Passageiros no Aeroporto Internacional de Faro.	16
Figura 4.3: Diferenciação da transformação logarítmica da série do Movimento de Passageiros no Aeroporto Internacional.	16
Figura 4.4: Função de Autocorrelação (a) e Autocorrelação Parcial (b) da série do Movimento de Passageiros no Aeroporto Internacional de Faro, sem tendência e sem sazonalidade.	17
Figura 4.5: Resíduos Padronizados do modelo $ARIMA(0,1,1)(0,1,0)_4$ de ajuste à série do Movimento de Passageiros no Aeroporto Internacional de Faro.	17
Figura 4.6: Resíduos Padronizados do modelo $ARIMA(0,1,0)(0,1,0)_4$ sem efeito do <i>outlier</i> detetado.	18
Figura 4.7: Função de Autocorrelação dos resíduos do modelo $ARIMA(0,1,0)(0,1,0)_4$ sem efeito do <i>outlier</i> detetado.....	18
Figura 4.8: Gráfico Quantil-Quantil dos resíduos do modelo $ARIMA(0,1,0)(0,1,0)_4$ sem efeito do <i>outlier</i> detetado.	19
Figura 4.9: Comparação entre a série do Movimento de Passageiros no Aeroporto Internacional de Faro e o modelo ajustado.	19
Figura 4.10: Previsão do número de Passageiros no Aeroporto Internacional de Faro entre 2018 e 2020.	20
Figura 4.11: Movimento de Passageiros entre o Aeroporto Internacional de Faro e outros Aeroportos Nacionais entre 2007 e 2017: (a) Observações trimestrais; (b) Observações anuais.	20
Figura 4.12: Diferenciação da série do Movimento de Passageiros entre o Aeroporto Internacional de Faro e outros Aeroportos Nacionais entre 2010 e 2017.	21
Figura 4.13: Função de Autocorrelação (a) e Autocorrelação Parcial (b) da série do Movimento de Passageiros entre o Aeroporto Internacional de Faro e outros Aeroportos Nacionais, sem tendência e sem sazonalidade.	22
Figura 4.14: Resíduos Padronizados do modelo $ARIMA(0,1,0)(2,1,0)_4$ de ajuste à série do Movimento de Passageiros entre o Aeroporto Internacional de Faro e outros Aeroportos Nacionais.	22
Figura 4.15: Função de Autocorrelação dos resíduos do modelo $ARIMA(0,1,0)(2,1,0)_4$	23
Figura 4.16: Gráfico Quantil-Quantil dos resíduos do modelo $ARIMA(0,1,0)(2,1,0)_4$	23
Figura 4.17: Comparação entre a série do Movimento de Passageiros entre o Aeroporto Internacional de Faro e outros Aeroportos Nacionais e o modelo ajustado.	24
Figura 4.18: Previsão do número de Passageiros entre o Aeroporto Internacional de Faro e outros Aeroportos Nacionais, de 2018 e 2020.	24

Figura 4.19: Movimento de Passageiros no Serviço Regional: (a) Observações trimestrais; (b) Observações anuais.	25
Figura 4.20: Diferenciação da série do Movimento de Passageiros no Serviço Regional Ferroviário entre 2008 e 2017.	26
Figura 4.21: Função de Autocorrelação (a) e Autocorrelação Parcial (b) da série do Movimento de Passageiros no Serviço Regional Ferroviário, sem tendência e sem sazonalidade.	26
Figura 4.22: Resíduos Padronizados do modelo $ARIMA(0,1,0)(0,1,1)_4$ de ajuste à série do Movimento de Passageiros no Serviço Regional Ferroviário.	27
Figura 4.23: Comparação entre a série do Movimento de Passageiros no Serviço Regional Ferroviário e o modelo ajustado.	27
Figura 4.24: Previsão do número de Passageiros no Serviço Regional Ferroviário, de 2018 a 2020.	28
Figura 4.25: Movimento de Passageiros no Serviço de Longo Curso: (a) Observações trimestrais; (b) Observações anuais.	28
Figura 4.26: Diferenciação da série do Movimento de Passageiros no Serviço Ferroviário de Longo Curso.	29
Figura 4.27: Função de Autocorrelação (a) e Autocorrelação Parcial (b) da série do Movimento de Passageiros no Serviço Ferroviário de Longo Curso, sem tendência e sem sazonalidade.	29
Figura 4.28: Resíduos Padronizados do modelo $ARIMA(2,1,0)(0,1,0)_4$ de ajuste à série do Movimento de Passageiros no Serviço Ferroviário de Longo Curso.	30
Figura 4.29: Comparação entre a série do movimento de passageiros no serviço de longo curso e o modelo ajustado.	31
Figura 4.30: Previsão do número de Passageiros no Serviço de Longo Curso, de 2018 a 2020.	31
Figura 4.31: Movimento de Passageiros do Guadiana (Vila Real de Santo António – Ayamonte): (a) Observações trimestrais; (b) Observações anuais.	32
Figura 4.32: Diferenciação da série do Movimento de Passageiros do Guadiana (Vila Real de Santo António – Ayamonte).	33
Figura 4.33: Função de Autocorrelação (a) e Autocorrelação Parcial (b) da série do Movimento de Passageiros do Guadiana, sem tendência e sem sazonalidade.	33
Figura 4.34: Resíduos Padronizados do modelo $ARIMA(0,1,1)(0,1,0)_4$ de ajuste à série do Movimento de Passageiros do Guadiana.	34
Figura 4.35: Comparação entre a série do Movimento de Passageiros do Guadiana e o modelo ajustado.	34
Figura 4.36: Previsão do número de passageiros do Guadiana, de 2018 e 2020.	35
Figura 4.37: Movimento de Passageiros nas carreiras da Ria Formosa: (a) Observações trimestrais; (b) Observações anuais.	36
Figura 4.38: Movimento de Passageiros nas Ligações Urbanas: (a) Observações trimestrais; (b) Observações anuais.	36
Figura 4.39: Diferenciação da série do Movimento de Passageiros nas Ligações Urbanas.	37

Figura 4.40: Função de Autocorrelação (a) e Autocorrelação Parcial (b) da série do Movimento das ligações Urbanas.	37
Figura 4.41: Resíduos Padronizados do modelo $ARIMA(0,1,0)(1,1,0)_4$ de ajuste à série do Movimento de Passageiros das ligações Urbanas.	38
Figura 4.42: Resíduos Padronizados do modelo $ARIMA(0,1,0)(1,1,0)_4$ sem efeito do <i>outlier</i> detetado.	38
Figura 4.43: Comparação entre a série do Movimento de Passageiros das ligações Urbanas e o modelo ajustado.	39
Figura 4.44: Previsão do número de passageiros das ligações Urbanas, de 2018 e 2020.	39
Figura 4.45: Movimento de Passageiros nas Ligações Inter-Urbanas: (a) Observações trimestrais; (b) Observações anuais.	40
Figura 4.46: Diferenciação da série do Movimento de Passageiros nas Ligações Inter-Urbanas.	40
Figura 4.47: Função de Autocorrelação (a) e Autocorrelação Parcial (b) da série do Movimento das ligações Inter-Urbanas.	41
Figura 4.48: Resíduos Padronizados do modelo $ARIMA(0,1,0)(1,1,0)_4$ de ajuste à série do Movimento de Passageiros das ligações Inter-Urbanas.	41
Figura 4.49: Comparação entre a série do Movimento de Passageiros das ligações Inter-Urbanas e o modelo ajustado.	42
Figura 4.50: Previsão do número de passageiros das ligações Inter-Urbanas, de 2018 e 2020.	42
Figura 4.51: Movimento de Passageiros nas Ligações Inter-Regionais: (a) Observações trimestrais; (b) Observações anuais.	43
Figura 4.52: Diferenciação da série do Movimento de Passageiros nas Ligações Inter-Regionais.	44
Figura 4.53: Função de Autocorrelação (a) e Autocorrelação Parcial (b) da série do Movimento das ligações Inter-Regionais.	44
Figura 4.54: Resíduos Padronizados do modelo $ARIMA(0,1,1)(0,1,0)_4$ de ajuste à série do Movimento de Passageiros das ligações Inter-Regionais.	45
Figura 4.55: Comparação entre a série do Movimento de Passageiros das ligações Inter-Regionais e o modelo ajustado.	45
Figura 4.56: Previsão do número de passageiros das ligações Inter-Regionais, de 2018 e 2020.	46
Figura 4.57: Movimento de Passageiros nas Ligações Internacionais: (a) Observações trimestrais; (b) Observações anuais.	46
Figura 4.58: Diferenciação da série do Movimento de Passageiros nas Ligações Internacionais.	47
Figura 4.59: Função de Autocorrelação (a) e Autocorrelação Parcial (b) da série do Movimento das ligações Internacionais.	47
Figura 4.60: Resíduos Padronizados do modelo $ARIMA(0,1,1)(0,1,0)_4$ de ajuste à série do Movimento de Passageiros das ligações Internacionais.	48
Figura 4.61: Comparação entre a série do Movimento de Passageiros das ligações Internacionais e o modelo ajustado.	48
Figura 4.62: Previsão do número de passageiros das ligações Internacionais, de 2018 e 2020.	49

Figura 4.63: Tráfego Médio Diário na A2 (Almodôvar/São Bartolomeu de Messines): (a) Observações trimestrais; (b) Observações anuais.	50
Figura 4.64: Diferenciação da série do Tráfego Médio Diário na A2 (Almodôvar/São Bartolomeu de Messines).	50
Figura 4.65: Função de Autocorrelação (a) e Autocorrelação Parcial (b) da série do Tráfego Médio Diário na A2.	50
Figura 4.66: Resíduos Padronizados do modelo $ARIMA(0,1,0)(0,1,0)_4$ de ajuste à série do Tráfego Médio Diário na A2.	51
Figura 4.67: Resíduos Padronizados do modelo $ARIMA(0,1,0)(0,1,0)_4$ sem efeito do <i>outlier</i> detetado.	51
Figura 4.68: Comparação entre a série do Tráfego Médio Diário na A2 e o modelo ajustado.....	52
Figura 4.69: Previsão do Tráfego Médio Diário na A2, de 2018 e 2020.	52
Figura 4.70: Tráfego Médio Diário na Ponte Internacional do Guadiana: (a) Observações trimestrais; (b) Observações anuais.	53
Figura 4.71: Diferenciação da série do Tráfego Médio Diário na Ponte Internacional do Guadiana.	54
Figura 4.72: Função de Autocorrelação (a) e Autocorrelação Parcial (b) da série do Tráfego Médio Diário na Ponte Internacional do Guadiana.	54
Figura 4.73: Resíduos Padronizados do modelo $ARIMA(0,1,0)(0,1,1)_4$ de ajuste à série do Tráfego Médio Diário na Ponte Internacional do Guadiana.	54
Figura 4.74: Resíduos Padronizados do modelo $ARIMA(0,1,0)(0,1,1)_4$ sem efeito do <i>outlier</i> detetado.	55
Figura 4.75: Comparação entre a série do Tráfego Médio Diário na Ponte Internacional do Guadiana e o modelo ajustado.....	56
Figura 4.76: Previsão do Tráfego Médio Diário na Ponte Internacional do Guadiana, de 2018 e 2020.	56
Figura 4.77: Tráfego Médio Diário na A22: (a) Observações trimestrais; (b) Observações anuais.	57
Figura 4.78: Diferenciação da série do Tráfego Médio Diário na A22.....	57
Figura 4.79: Função de Autocorrelação (a) e Autocorrelação Parcial (b) da série do Tráfego Médio Diário na A22.	58
Figura 4.80: Resíduos Padronizados do modelo $ARIMA(0,1,0)(0,1,0)_4$ de ajuste à série do Tráfego Médio Diário na A22.	58
Figura 4.81: Resíduos Padronizados do modelo $ARIMA(0,1,0)(0,1,0)_4$ sem efeito do <i>outlier</i> detetado.	59
Figura 4.82: Comparação entre a série do Tráfego Médio Diário na A22 e o modelo ajustado.....	59
Figura 4.83: Previsão do Tráfego Médio Diário na A22, de 2018 e 2020.	60
Figura 4.84: Número de deslocações de bicicleta, registadas pela <i>app</i> Strava, em toda a região do Algarve, de 2013 até 2016.....	61
Figura 4.85: Número de deslocações de bicicleta, registadas pela <i>app</i> Strava diariamente em 2016, em toda a região do Algarve.	62

Figura 4.86: Número de deslocações de bicicleta, registadas pela <i>app</i> Strava mensalmente em 2016, em toda a região do Algarve...	62
Figura 4.87: Número médio de deslocações de bicicleta, por hora, em toda a região do Algarve, registadas pela <i>app</i> Strava.	64

Lista de Tabelas

Tabela A.1: Valores obtidos da previsão trimestral do movimento de passageiros no Aeroporto Internacional de Faro, de 2018 a 2020.	72
Tabela A.2: Valores da previsão trimestral do movimento de passageiros entre o Aeroporto Internacional de Faro e outros Aeroportos nacionais, de 2018 a 2020.	72
Tabela B.1: Valores da previsão trimestral do movimento de passageiros no Serviço Regional, de 2018 a 2020.	72
Tabela B.2: Valores da previsão trimestral do movimento de passageiros no Serviço de Longo Curso, de 2018 a 2020.	72
Tabela C.1: Valores obtidos da previsão trimestral do movimento de passageiros nas carreiras do Guadiana, de 2018 a 2020.	73
Tabela D.1: Valores obtidos da previsão trimestral do movimento de passageiros nas Ligações Urbanas, de 2018 a 2020.	73
Tabela D.2: Valores da previsão trimestral do movimento de passageiros nas Ligações Inter-Urbanas, de 2018 a 2020.	73
Tabela D.3: Valores da previsão trimestral do movimento de passageiros nas Ligações Inter-Regionais, de 2018 a 2020.	73
Tabela D.4: Valores da previsão trimestral do movimento de passageiros nas Ligações Internacionais, de 2018 a 2020.	73
Tabela E.1: Valores da previsão trimestral do tráfego médio diário na A2, de 2018 a 2020.	74
Tabela E.2: Valores da previsão trimestral do tráfego médio diário na Ponte Internacional do Guadiana, de 2018 a 2020.	74
Tabela E.3: Valores da previsão trimestral do movimento do tráfego médio diário na A22, de 2018 a 2020.	74

Lista de Abreviaturas

ACF – Autocorrelation Function

ADF – Augmented Dickey-Fuller

AIC – Akaike Information Criterion

AMAL – Comunidade Intermunicipal do Algarve

AR – Autoregressive

ARMA – Autoregressive Moving Average

ARIMA – Autoregressive Integrated Moving Average

CCDR – Comissão de Coordenação e Desenvolvimento Regional

GEE – Gases com efeito de estufa

LNEC – Laboratório Nacional de Engenharia Civil, I.P.

MA – Moving Average

PACF – Partial Autocorrelation Function

SARIMA – Seasonal Autoregressive Integrated Moving Average

TMD – Tráfego Médio Diário

1. Introdução

1.1. Enquadramento

A região do Algarve é conhecida pelo seu clima temperado mediterrâneo, pela beleza das suas praias e paisagens naturais, fazendo desta região uma das zonas turísticas da Europa mais procuradas por turistas nacionais e estrangeiros. Este reconhecimento tem vindo a aumentar, fazendo com que o turismo tenha vindo a crescer ao longo dos anos.

De acordo com os Censos 2011, entre 2001 e 2011, a população do Algarve aumentou 14,1%, tendo sido a região do país que mais cresceu em termos de população nesta década [24]. No entanto, a partir de 2011 a população residente na região do Algarve deixou de crescer, tendo começado a sofrer um ligeiro decréscimo até 2017 [25]. À data da realização dos Censos 2011, a população estrangeira residente na região do Algarve, representava cerca de 11,6% da população total residente, fazendo do Algarve a região do país com maior percentagem relativa de cidadãos estrangeiros. Na última década, verificou-se em todos os municípios do Algarve, um crescimento da população estrangeira relativamente ao total da população da região, o que demonstra o poder atrativo da região em termos de deslocações. [24].

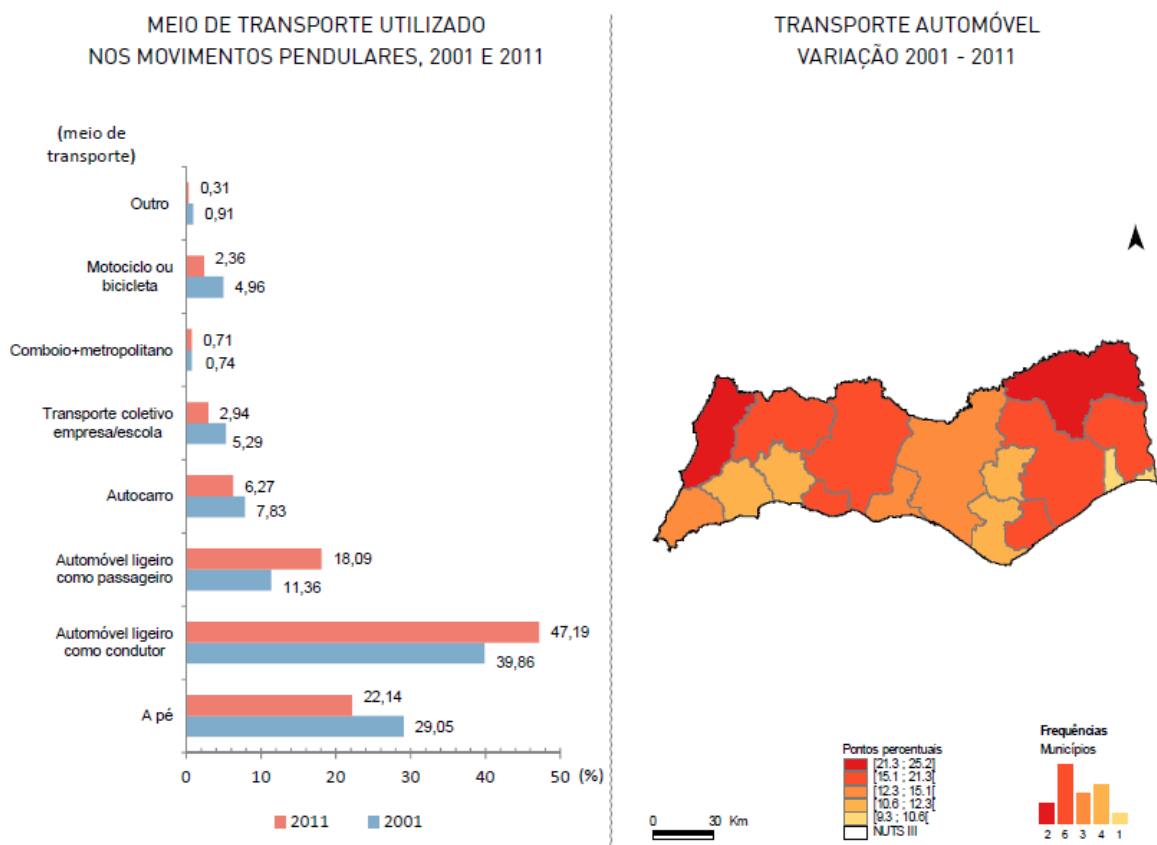
Para tentar acompanhar esta tendência de evolução, os serviços de transporte terão de sofrer algumas alterações, uma vez que ainda se verifica a utilização do transporte individual como principal modo de deslocação, o que coloca em causa o conceito de mobilidade sustentável da região.

A Figura 1.1. apresenta a distribuição dos vários modos de transporte utilizados nas deslocações pendulares¹, onde se pode verificar a dominância do automóvel face aos restantes. Cerca de 65,3% da população da região do Algarve recorre ao transporte individual para as suas deslocações para o trabalho ou local de estudo, o que fica ligeiramente acima da média do país, 61,6%.

Entre 2001 e 2011, a região do Algarve registou um crescimento de 14,1 pontos percentuais na utilização do automóvel. Por outro lado, as deslocações a pé bem como o uso de transportes coletivos como o autocarro e o comboio, foram perdendo importância.

O aumento do transporte individual como principal modo de deslocação tem contribuído para o aumento do tráfego rodoviário, do congestionamento, e para a intensificação dos impactos ambientais. Ao longo dos últimos anos tem-se vindo a verificar uma crescente preocupação em relação a assuntos relacionados com as emissões de dióxido de carbono na atmosfera, cujos efeitos se têm vindo a sentir de um modo cada vez mais significativo. A emissão descontrolada dos gases com efeito de estufa, deve-se em parte ao grande crescimento populacional que se verificou no século XX e ao desenvolvimento económico de diversos países, que resultaram em problemas como o aquecimento global, que se têm vindo a agravar, colocando em risco a vida do planeta. Em 2005, Portugal atingiu o seu pico de emissões de gases com efeito de estufa, tendo-se registado um aumento de cerca de 44%, em comparação com os níveis que se registavam em 1990. Se não forem tomadas medidas a nível global, prevê-se um aumento da temperatura média à superfície entre 1,8°C e 4°C até 2100, o que poderá levar à subida do nível da água do mar e, consequentemente, ao desaparecimento de zonas costeiras. [12]

¹ Deslocações Pendulares dizem respeito às deslocações feitas de casa para o trabalho ou de casa para o local de estudo.



Fonte: Censos 2011 [24]

Figura 1.1: Modo de transporte utilizado nos movimentos pendulares (%).

Em Portugal, de acordo com a Agência Portuguesa do Ambiente, o setor dos transportes contribuiu em cerca de 24% para o total das emissões de gases com efeito de estufa (GEE), em 2015. No período de 1990 a 2016, as emissões de GEE do setor dos transportes cresceram um total de 63%, onde se registou, no período de 2013 a 2016, um aumento de 5,1%. [2]

Para contornar este problema, várias medidas têm vindo a ser tomadas de forma a promover um desenvolvimento sustentável. As políticas nacionais e comunitárias na área dos transportes e ambiente têm como preocupação a redução das emissões de gases com efeito de estufa e a descarbonização da mobilidade e transportes até 2050. Em 2017 foi concluído o Plano de Ação de Mobilidade Urbana Sustentável (PAMUS) da região Algarve, com a supervisão científica do LNEC. Este plano insere-se no objetivo temático do Programa Operacional do Algarve 2014-2020 relativo à descarbonização da economia e do setor dos transportes: “Apoiar a transição para uma economia de baixo teor de carbono em todos os setores”, inserido na prioridade de investimento “Promoção de baixo teor de carbono para todos os tipos de território, nomeadamente as zonas urbanas, incluindo a promoção da mobilidade urbana multimodal sustentável e medidas de adaptação relevantes para a atenuação” [3].

Em novembro de 2017, Portugal assumiu a Presidência da Aliança Internacional de Descarbonização dos Transportes, iniciativa lançada em Bona durante a Conferência das Nações Unidas sobre Mudanças Climáticas (COP 23), com o objetivo de atingir a neutralidade carbónica nos transportes antes de 2050 [3].

O tema do presente projeto insere-se na linha de investigação “Mobilidade sustentável, transportes e novos serviços de mobilidade de baixo carbono” proposta pela Eng^a. Elisabete Arsénio para o plano de

ID&I 2013-2020 do Departamento de Transportes do LNEC, tendo sido motivado pelo trabalho prévio com a AMAL acima referido e com a CCDR Algarve que tem vindo a reunir informação sobre os vários modos de transporte na região, desde 2009 ². Este projeto pretende assim dar um contributo para a análise integrada dos dados existentes numa perspetiva multimodal, possibilitando a sua transformação em informação útil ao planeamento da mobilidade e transportes, através da aplicação de ferramentas de análise estatística.

1.2. Objetivos

O projeto consiste na análise de tendências de evolução dos padrões da mobilidade de passageiros numa perspetiva multimodal na região do Algarve, através da análise dos dados existentes na CCDR do Algarve e AMAL. Os resultados pretendem dar um contributo para apoiar as referidas entidades no desenvolvimento de políticas para a mobilidade sustentável. A utilidade do projeto centra-se na possibilidade de planear antecipadamente os padrões de mobilidade esperados nos próximos anos, recorrendo a modelos estatísticos.

Os objetivos desta dissertação estão associados a várias questões em investigação às quais se pretende dar resposta no final do trabalho:

- ✓ Que padrões de mobilidade se observam nos diversos modos de transporte na região do Algarve?
- ✓ Quais as tendências que podem ser esperadas nos próximos anos?
- ✓ De acordo com os modelos de previsão estimados e respetivos resultados, que recomendações podem ser úteis às entidades responsáveis pelo planeamento da mobilidade e transportes, para melhorar a acessibilidade e mobilidade na região?

1.3. Metodologia

Para a concretização dos objetivos foram analisados os dados do movimento de passageiros nos transportes aéreo, ferroviário, marítimo-fluvial, coletivo rodoviário, e os dados do tráfego médio diário na rede rodoviária principal, disponibilizados pela CCDR Algarve [10]. Foram também analisados os dados das deslocações de bicicleta, disponibilizados pela AMAL. Na previsão de cada uma das séries temporais, foram utilizados os modelos autorregressivos integrados e de médias móveis para séries com sazonalidade, recorrendo-se ao *software R* ³ para proceder à estimação dos modelos.

A metodologia utilizada baseia-se na metodologia de *Box & Jenkins* [8] para a previsão de séries temporais, que se centra principalmente na análise gráfica da série temporal em estudo, verificar a sua estacionariedade, estimar os parâmetros do modelo, avaliar o modelo através da análise residual do mesmo e utilizá-lo na previsão dos valores futuros. Para realizar a previsão de cada uma das séries temporais foram utilizados os modelos autorregressivos integrados e de médias móveis para séries com sazonalidade (SARIMA). Optou-se pela sua utilização uma vez que os modelos de regressão são uns dos modelos mais bem-sucedidos na previsão do fluxo de passageiros (*Liu & Chen, 2017*) [27].

² Informação disponível em: <http://mt.ccdr-alg.pt/>

³ Software disponível em: <https://cran.r-project.org/>

Uma vez que os dados disponibilizados apresentam, no geral, valores trimestrais de 2007 a 2017, as séries temporais são consideradas curtas pois são constituídas por 44 observações. Por esta razão, optou-se por não retirar dados para fazer a avaliação da previsão, pois iria tornar o comprimento da série ainda menor. Sendo o ano de 2020 o horizonte do Plano de Ação para a Mobilidade Sustentável da região do Algarve, a previsão será feita para três anos, de 2018 a 2020.

1.4. Estrutura do Relatório de Projeto

Este documento encontra-se dividido em cinco capítulos. O primeiro e presente capítulo introduz o projeto e o contexto em que está envolvido, dando a conhecer os seus principais objetivos e a metodologia utilizada no desenvolvimento do mesmo.

O segundo capítulo é dedicado ao enquadramento teórico, sendo apresentado o conceito de séries temporais e previsão. Em continuidade, no terceiro capítulo apresenta-se a metodologia utilizada no desenvolvimento do projeto bem como os modelos utilizados na previsão dos valores futuros das séries temporais.

No quarto capítulo encontram-se os resultados da análise dos dados, onde é apresentada a análise descritiva de cada uma das séries temporais em estudo para os diversos tipos de transporte, a sua modelação e previsão.

No quinto e último capítulo apresentam-se as principais conclusões do projeto, bem como as recomendações a sugerir às entidades responsáveis pelo planeamento da mobilidade e transportes na região.

2. Análise e Previsão de Séries Temporais

2.1. Conceitos Básicos

Uma série temporal é um conjunto de observações estatisticamente relacionadas, associadas a determinado fenómeno aleatório e recolhidas sequencialmente ao longo do tempo. É um caso particular de um processo estocástico, ou seja, é uma sequência de variáveis aleatórias ordenadas no tempo em que os valores observados são designados por realização ou observação (*Brockwell & Davis*, 1991) [9].

Os principais objetivos do estudo das séries temporais passam pela descrição, modelação, previsão e controlo (*Ehlers*, 2009) [17]:

- ✓ **Descrição:** Através da análise gráfica da série podem ser identificados alguns padrões de tendência, variações sazonais ou cíclicas, existência de *outliers* ou de pontos de viragem.
- ✓ **Modelação:** Após a descrição do comportamento da série, são construídos modelos que permitam explicar o seu comportamento no período observado.
- ✓ **Previsão:** Prever os valores futuros da série e a sua evolução com base nas observações registadas no passado e com a ajuda dos modelos construídos para explicar o seu comportamento.
- ✓ **Controlo:** Procurar modificar o comportamento futuro do processo através do ajustamento de variáveis controláveis. Este objetivo não será posto em prática neste projeto.

Uma série temporal Y_t pode ser decomposta e escrita em função de quatro componentes (*Murteira*, 2000) [32]:

$$Y_t = f(T_t, S_t, C_t, \varepsilon_t) \quad (2.1)$$

Onde T_t é a componente de tendência, S_t a componente sazonal, C_t a componente cíclica e ε_t a componente residual ou ruído, definidas como:

- ✓ **Tendência (T_t):** Esta componente está relacionada com a evolução da série ao longo do tempo. É definida como a inclinação da série temporal, pelo que se caracteriza por movimentos ascendentes ou descendentes dos seus valores, registados num longo período de tempo. Uma série é estacionária em média quando não apresenta qualquer tipo de tendência ao longo do tempo.
- ✓ **Sazonalidade (S_t):** Esta componente representa os movimentos oscilatórios que ocorrem em intervalos de curta duração, que se repetem em intervalos aproximadamente constantes no tempo. A sazonalidade traduz a influência de fatores periódicos nos valores observados da série, tais como as estações do ano, festividades como o Natal ou a Páscoa, entre outros.
- ✓ **Componente Cíclica (C_t):** Um ciclo corresponde a um movimento oscilatório de longa duração. Esta componente está relacionada, por exemplo, com as fases de expansão e recessão económica no caso de séries económicas.
- ✓ **Componente Residual ou Ruído (ε_t):** Corresponde ao efeito aleatório da série e está relacionada com a imprevisibilidade e aleatoriedade das observações. É um movimento oscilatório de curta

duração que representa tudo o que não pode ser atribuído às outras três componentes. Esta componente encontra-se em todas as séries temporais uma vez que reflete um determinado comportamento que pode não ser explicado pelas restantes componentes.

As duas decomposições mais comuns correspondem a decomposições para um modelo aditivo (Equação 2.2) e para um modelo multiplicativo (Equação 2.3):

$$Y_t = T_t + S_t + C_t + \varepsilon_t \quad (2.2)$$

$$Y_t = T_t * S_t * C_t * \varepsilon_t \quad (2.3)$$

A escolha da utilização de cada um dos modelos passa por analisar o comportamento da amplitude sazonal⁴: quando a amplitude se mantém aproximadamente constante ao longo do tempo é utilizado um modelo aditivo, caso contrário, se esta apresentar variações, então o modelo multiplicativo pode ser o mais adequado.

2.2. Elementos para a Previsão

2.2.1. Transformação de *Box-Cox*

Na análise de séries temporais por vezes verificamos que os dados não apresentam variância aproximadamente constante. Nestes casos, a utilização de uma transformação de *Box-Cox* é bastante útil para estabilizar a variância.

Sendo X_1, \dots, X_t os dados da série original, a transformação de *Box-Cox* consiste em encontrar um valor de λ tal que os dados transformados Y_1, \dots, Y_t se aproximem de uma distribuição normal (*Box & Cox*, 1964) [7]. Esta transformação é dada por:

$$Y_t = \begin{cases} \ln(X_t), & \text{se } \lambda = 0 \\ (Y_t^\lambda - 1) / \lambda, & \text{se } \lambda \neq 0 \end{cases} \quad (2.4)$$

2.2.2. Estacionariedade

A estacionariedade de uma série temporal é observada quando esta não apresenta tendência crescente ou decrescente, movimentos periódicos ou cíclicos, as suas observações variam em torno de uma média constante, e a variância das flutuações não se altera ao longo do tempo. No entanto, se uma série não é estacionária em média, não significa que não seja estacionária em variância e covariância (*Wei*, 2007) [42].

Geralmente, quando nos referimos a estacionariedade de uma série referimo-nos à estacionariedade fraca, a estacionariedade implica estacionariedade fraca, mas o recíproco não é necessariamente verdadeiro. Teoricamente, uma série Y_t é fracamente estacionária quando:

1. A sua média é constante: $E(Y_t) = \mu$, onde μ é constante

⁴ A amplitude sazonal de uma série temporal diz respeito à diferença entre o maior e o menor valor que a série assume, num mesmo ano.

2. A sua variância é constante e finita: $Var = cov(Y_t, Y_t) = \sigma^2 < \infty$, onde σ^2 é constante
3. A sua covariância é invariante ao longo do tempo: $cov(Y_t, Y_s) = cov(Y_{t+r}, Y_{s+r}), \forall r, s, t$

Como a maioria dos métodos de análise de séries temporais pressupõe que estas sejam estacionárias, é usada frequentemente a transformação clássica para tornar uma série estacionária, que consiste em diferenciar sucessivamente a série original com o objetivo de estabilizar a média da série.

Independentemente do observado através da representação gráfica da série temporal, será sempre vantajoso realizar testes estatísticos para poder avaliar a estacionariedade da série de forma mais correta.

Uma série temporal pode apresentar tendência determinística ou estocástica. Considerando, como exemplo, o seguinte modelo:

$$y_t = \beta_0 + \beta_1 t + \rho y_{t-1} + \varepsilon_t \quad (2.5)$$

Onde β_0 é o *drift* da série e β_1 é o coeficiente de tendência.

Verifica-se a existência de tendência determinística se $\rho = 0$, ou seja, o processo é estacionário em torno de uma tendência linear. Por outro lado, existe tendência estocástica se $\rho = 1$ e $\beta_1 = 0$, obtendo-se um passeio aleatório⁵ com deriva ou *drift*.

Para averiguar se uma série é ou não estacionária, basta verificar se $\rho = 1$, testando assim a existência de uma raiz unitária. Os testes de raiz unitária permitem detetar se a série foi suficientemente diferenciada para se tornar estacionária, onde se pretende testar a seguinte hipótese nula:

$$H_0: \rho = 1 \quad vs \quad H_1: \rho < 1 \quad (2.6)$$

A hipótese nula não é rejeitada se $valor-p > \alpha$, sendo α o nível de significância escolhido, havendo então evidência estatística de que existe uma raiz unitária, logo a série é não estacionária.

O teste mais utilizado para detetar a existência de raízes unitárias é o teste de *Dickey-Fuller* Aumentado (ADF) [16], que é aplicado ao seguinte modelo:

$$\Delta y_t = \beta_0 + \beta_1 t + (\rho - 1)y_{t-1} + \sum_{i=1}^m \alpha_i \Delta y_{t-i} + \varepsilon_t \quad (2.7)$$

Onde β_0 é o *drift* da série, β_1 é o coeficiente de tendência, δ é o coeficiente de presença de raiz unitária e m é o número de defasamentos considerados na série. Este teste pretende testar a seguinte hipótese nula:

$$H_0: \rho - 1 = 0 \quad vs \quad H_1: \rho - 1 < 0 \quad (2.8)$$

Correspondendo a hipótese nula à existência de raiz unitária, ou seja, à não-estacionariedade da série. Para realização deste teste será utilizada a função *adf.test* do pacote “*tseries*” do R [41].

⁵ Passeio Aleatório: Processo aleatório com tendência estocástica, que não manifesta condições de estacionariedade e onde os registos da série não permitem prever o seu futuro.

2.2.3. Função de Autocorrelação

A função de autocorrelação (ACF) é utilizada para identificar a correlação que uma determinada série temporal apresenta com ela própria em diferentes períodos de tempo. É definida por:

$$\rho_k = \frac{cov(Y_t, Y_{t-k})}{var(Y_t)}, k \in \mathbb{N} \quad (2.9)$$

Onde Y_t corresponde ao valor observado no instante t e k o número de períodos de desfasamento.

A função de autocorrelação permite determinar a correlação entre duas variáveis espaçadas k períodos (*lag* ou desfasamento) e caracterizar o desenvolvimento de Y_t ao longo do tempo, demonstrando a força da correlação entre o valor observado no presente e os valores observados no passado, e também como valores discrepantes no presente afetam os valores futuros da variável estocástica.

A ACF pode também ser útil para verificar a estacionariedade e identificar a presença de sazonalidade, escolher modelos e fazer diagnósticos sobre regressões (Enders, 2008) [18].

2.2.4. Função de Autocorrelação Parcial

As autocorrelações para intervalos sucessivos são intrinsecamente dependentes, ou seja, se o primeiro elemento da série está correlacionado com o segundo elemento que por sua vez está correlacionado com o terceiro, então o primeiro elemento está de alguma forma também correlacionado com o terceiro. A função de autocorrelação parcial (PACF) permite então obter uma informação sobre autocorrelações na série sem a existência desta influência sucessiva.

A autocorrelação parcial de atraso k corresponde à autocorrelação entre Y_t e Y_{t-k} que não é explicada pelos atrasos entre 1 a k :

$$\varphi_{kk} = corr(Y_t, Y_{t-k} | Y_{t-1}, \dots, Y_{t-k+1}) \quad (2.10)$$

A função de autocorrelação parcial, dá-nos a correlação entre uma dada variável no instante t e um dos seus desfasamentos, retirando os efeitos dos restantes desfasamentos. Ou seja, define a correlação entre as observações Y_t e Y_{t-k} removendo o efeito das observações entre Y_{t-k} e Y_t . Esta remoção é feita determinando Y_t e Y_{t-k} como combinação linear das observações $Y_{t-1}, Y_{t-2}, \dots, Y_{t-k+1}$ (Cryer & Chan, 2008) [14].

3. Modelação

Neste capítulo vai ser apresentada a metodologia utilizada no desenvolvimento do projeto bem como os modelos utilizados na previsão dos valores futuros das séries temporais.

A metodologia utilizada baseia-se na metodologia de *Box & Jenkins* [8] para a previsão de séries temporais, que se centra essencialmente nos seguintes passos:

1. Análise gráfica da série temporal, onde poderão ser identificados padrões, tendências, sazonalidade, bem como a existência de observações discrepantes ou atípicas (*outliers*);
2. Verificar a estacionariedade da série temporal através de um teste de raiz unitária;
3. Estimar os parâmetros do modelo proposto, através da análise dos gráficos das funções de autocorrelação e autocorrelação parcial, e de critérios de informação;
4. Avaliar o modelo, através de medidas de diagnóstico;
5. Reformular o modelo, caso seja necessário;
6. Utilizar o modelo para previsão dos valores futuros.

3.1. Modelos de Séries Temporais

Muitas têm sido as técnicas de modelação estatística, desenvolvidas nos últimos anos, para a análise e previsão de séries temporais, no entanto ainda todos os métodos possuem um erro de previsão, que depende em grande parte da componente aleatória da série temporal.

Os modelos mais utilizados são os modelos de séries temporais lineares que pertencem à família dos modelos autorregressivos integrados e de médias móveis, ARIMA. Serão ainda definidos os casos particulares dos modelos ARIMA: os modelos autorregressivos (AR), os modelos de médias móveis (MA), e os modelos ARMA que consistem na combinação dos modelos AR e MA.

3.1.1. Modelo Autorregressivo

Uma série temporal Y_t é um processo autorregressivo de ordem p , $AR(p)$, se:

$$Y_t = \mu + \varphi_1 Y_{t-1} + \varphi_2 Y_{t-2} + \dots + \varphi_p Y_{t-p} + \varepsilon_t = \mu + \sum_{i=1}^p \varphi_i Y_{t-i} + \varepsilon_t \quad (3.1)$$

$$\varepsilon_t \sim WN(0, \sigma_\varepsilon^2) \quad (3.2)$$

Onde $\varphi_1, \dots, \varphi_p$ são constantes fixas e não nulas, designadas por parâmetros de autorregressão, p é a ordem de desfasamento (*lag*) e ε_t é um processo de ruído branco⁶ que assinala a nova informação recebida no passo t .

⁶ Ruído Branco: Sequência de variáveis aleatórias não correlacionadas, provenientes da mesma distribuição, com média (μ_ε) e variância (σ_ε^2) constantes. Pode ser indicado como: $\varepsilon_t \sim WN(\mu_\varepsilon, \sigma_\varepsilon^2)$.

Considerando o operador de desfasamento B , onde $BY_t = Y_{t-1}$, a equação 3.1 pode ser escrita de forma equivalente:

$$\varphi(B)Y_t = \mu + \varepsilon_t, \text{ onde } \varphi(B) = 1 - \varphi_1 B - \varphi_2 B^2 - \dots - \varphi_p B^p \quad (3.3)$$

Por definição, para um modelo autorregressivo, a equação característica é dada pela equação $\varphi(B) = 0$, onde B é, por convenção, um número real ou complexo. O processo $AR(p)$ é estacionário se e só se todas as raízes da equação característica tiverem valor absoluto superior a 1 (Cowpertwait & Metcalfe, 2009) [13].

Um modelo $AR(p)$ é descrito por:

1. Uma função de autocorrelação, ACF, infinita e com queda exponencial após p lags;
2. Uma função de autocorrelação parcial, PACF, igual a zero para desfasamentos superiores ao lag p .

3.1.2. Modelo de Médias Móveis

Uma série temporal Y_t é um processo de médias móveis de ordem q , $MA(q)$, se:

$$Y_t = \mu + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} = \mu + \sum_{i=0}^q \theta_i \varepsilon_{t-i} \quad (3.4)$$

$$\varepsilon_t \sim WN(0, \sigma_\varepsilon^2) \quad (3.5)$$

Onde μ é a média do processo, $\theta_0 = 1$ e $\theta_1, \dots, \theta_q$ são constantes fixas e não nulas, designadas por parâmetros de médias móveis, q é a ordem da média móvel e ε_t é um processo de ruído branco que assinala a nova informação recebida no passo t .

Tal como no processo autorregressivo, considerando o operador de desfasamento B , a equação 3.4 pode ser escrita de forma equivalente:

$$Y_t = \mu + \theta(B)\varepsilon_t \quad (3.6)$$

Onde $\theta(B) = 1 + \theta_1 B + \theta_2 B^2 + \dots + \theta_q B^q$.

Uma vez que os processos de médias móveis são uma soma finita de termos de um processo de ruído branco então são estacionários e, consequentemente, possuem média e covariância independentes do tempo. Sendo μ a média do processo $MA(q)$, e visto que os termos são mutuamente independentes, a variância é dada por $\sigma_\varepsilon^2(1 + \theta_1^2 + \dots + \theta_q^2)$ (Cowpertwait & Metcalfe, 2009) [13].

Um modelo $MA(q)$ é descrito por:

1. Uma função de autocorrelação, ACF, igual a zero para desfasamentos superiores ao lag q .
2. Uma função de autocorrelação parcial, PACF, infinita e com queda exponencial após o lag q .

3.1.3. Modelo Autorregressivo e de Médias Móveis

Uma série temporal Y_t é um processo autorregressivo de ordem p e de médias móveis de ordem q , $ARMA(p, q)$, se:

$$Y_t = \mu + \varphi_1 Y_{t-1} + \dots + \varphi_p Y_{t-p} + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t \quad (3.7)$$

$$Y_t = \mu + \sum_{i=1}^p \varphi_i Y_{t-i} + \sum_{i=0}^q \theta_i \varepsilon_{t-i} \quad (3.8)$$

$$\varphi(B)Y_t = \mu + \theta(B)\varepsilon_t \quad (3.9)$$

Por combinação dos processos $AR(p)$ e $MA(q)$ obtém-se então o processo $ARMA(p, q)$. Se $p = 0$ então o processo é $MA(q)$ e se $q = 0$ então o processo é $AR(p)$. Os coeficientes p e q são escolhidos através da análise das funções de autocorrelação, ACF e PACF, no entanto, no caso dos modelos $ARMA$, a determinação destes coeficientes é um procedimento incerto devido à sua dificuldade.

A função de autocorrelação de um modelo $ARMA(p, q)$ combina comportamentos dos modelos $AR(p)$ e $MA(q)$, mas ao serem considerados *lags* inferiores a q , a função é idêntica à do modelo $AR(p)$.

O modelo $ARMA$ é mais adequado quando as séries temporais são estacionárias. Se a série não é estacionária, utilizam-se os modelos $ARIMA$. Um modelo $ARIMA(p, d, q)$ é um modelo aplicado a uma série que foi diferenciada d vezes até se tornar estacionária, conforme se apresenta em seguida.

3.1.4. Modelo Autorregressivo Integrado de Médias Móveis

Um modelo autorregressivo integrado de médias móveis é uma generalização dos modelos $ARMA$, em que incorpora séries não estacionárias. Assim, tal como os métodos anteriores, descreve o comportamento de uma variável em termos dos seus valores passados (*Brockwell & R. A. Davis, 2002*) [9].

Os modelos $ARIMA(p, d, q)$ apresentam três parâmetros, o parâmetro p refere-se à ordem da componente autorregressiva, o parâmetro d diz respeito ao número de diferenciações necessárias para tornar a série estacionária, e o parâmetro q refere-se à ordem da componente de médias móveis.

Como se referiu anteriormente, a estacionariedade de uma série temporal implica que esta tenha média e variância constantes e covariância invariante, dependendo apenas do desfasamento temporal. Assim, a diferenciação é utilizada para diferenciar a série. Então, dada uma série temporal Y_t , a primeira diferença é dada pela diferença entre dois valores consecutivos: Y_t e Y_{t-1} .

$$\Delta Y_t = Y_t - Y_{t-1} \quad (3.10)$$

Considerando o operador de desfasamento B , onde $B^d Y_t = Y_{t-d}$, a equação da primeira diferença (3.10) pode ser dada por $\Delta Y_t = (1 - B)Y_t$.

Após ser feita a primeira diferenciação, se a série ainda não estiver estacionária em média, volta-se a diferenciar até que esta fique estabilizada. Depois da série ter sido diferenciada d vezes, tem-se $(1 - B)^d Y_t$, onde $d \geq 1$, já é possível utilizar o modelo $ARMA(p, q)$ pois a série resultante já é estacionária. A expressão do modelo $ARIMA(p, d, q)$ é então dada por:

$$(1 - \varphi_1 B - \dots - \varphi_p B^p)(1 - B)^d Y_t = \mu + (1 + \theta_1 B + \theta_2 B^2 + \dots + \theta_q B^q) \varepsilon_t \quad (3.11)$$

$$\varphi(B)(1 - B)^d Y_t = \mu + \theta(B) \varepsilon_t \quad (3.12)$$

Para aplicar um modelo ARIMA, será necessário começar por diferenciar a série temporal d vezes até esta se tornar estacionária em média, de forma a determinar o valor do parâmetro d , passando depois para a estimação dos parâmetros p e q , através da análise dos gráficos da ACF e da PACF.

Nem sempre é fácil estimar os valores dos parâmetros anteriormente referidos dada a complexidade associada. No entanto, existem métodos que permitem estimar os parâmetros ótimos do modelo ARIMA de forma automática (*Hyndman & Khandalar, 2008*) [23]. Os dois principais métodos de estimação dos parâmetros do ARIMA são o método de máxima verosimilhança e o método dos mínimos quadrados. A partir de um conjunto de dados e de um modelo estatístico, o método de máxima verosimilhança permite estimar os parâmetros do modelo que maximizam a probabilidade de ocorrência dos dados observados. Já o método dos mínimos quadrados procura encontrar o melhor ajuste para um conjunto de dados de forma a minimizar a soma dos quadrados das diferenças entre os valores estimados e os valores observados. (*Box & Jenkins, 1994*) [8].

3.1.5. Modelos Autorregressivo Integrado de Médias Móveis Sazonal

O modelo autorregressivo Integrado de Médias Móveis Sazonal (SARIMA) corresponde a uma generalização do modelo ARIMA onde é possível tratar da sazonalidade de uma série não estacionária (*Box & Jenkins, 1994*) [8].

Os modelos SARIMA são representados por $ARIMA(p, d, q)(P, D, Q)_m$ onde m representa o número de estações e os parâmetros P , D e Q têm o mesmo significado de p , d , q do modelo ARIMA, mas correspondem à parte sazonal do modelo.

Tal como para os modelos ARIMA, o primeiro passo para ajustar um modelo sazonal aos dados passa por determinar os valores de d e D que tornam a série estacionária e que removem a maior parte da sazonalidade existente. Posteriormente, os valores de p , P , q e Q devem ser especificados com base nas funções de autocorrelação e autocorrelação parcial da série diferenciada, tal como acontece nos modelos ARIMA.

3.2. Seleção do Modelo de Previsão

3.2.1. Critério de Informação de Akaike

Na fase de seleção do modelo muitas das vezes existem vários modelos que se consideram adequados aos dados. Uma forma de escolher de entre estes modelos é através dos critérios de informação que, para além de terem em conta a qualidade do ajuste, ainda penalizam a inclusão de parâmetros em excesso.

Em séries temporais o critério de informação mais utilizado é o Critério de Informação de Akaike (1974) (AIC) definido por [1]:

$$AIC = -2 \log(L) + 2k \quad (3.13)$$

Onde L representa a função de verosimilhança do modelo, que permite que o critério valorize a sua precisão, e k o número de parâmetros considerados, que permite ao critério penalizar os modelos com maior número de parâmetros. Para um modelo $ARIMA(p, d, q)$, tem-se $k = p + d + q$. O AIC representa o desvio entre o modelo proposto e os dados, sendo um modelo tanto melhor quanto menor o valor do AIC. No entanto, para que os modelos sejam comparáveis e os critérios de informação possam ser utilizados, é necessário que os modelos a comparar correspondam a estimativas referentes ao mesmo período amostral.

Existem ainda outros critérios de informação, que correspondem a transformações do AIC, sendo este o critério utilizado no desenvolvimento deste projeto para a seleção dos modelos.

3.3. Diagnóstico do Modelo de Previsão

Depois de definido um modelo de ajuste à série temporal em estudo, é necessário verificar se este é adequado aos dados através da observação do comportamento dos resíduos:

$$resíduo = valor\ observado - valor\ ajustado \quad (3.14)$$

Nesta fase de diagnóstico do modelo é necessário verificar se os resíduos apresentam uma distribuição aproximadamente normal, se os erros se distribuem aleatoriamente em torno de zero e com variância aproximadamente constante, e ainda verificar que estes não estejam autocorrelacionados ao longo do tempo.

Estas hipóteses vão ser testadas estatisticamente através de testes específicos para cada uma delas.

Para testar a existência de autocorrelação entre os primeiros B lags da série temporal será utilizado o teste de *Ljung-Box* (1978) [28], utilizando a função *Box.test* do R e escolhendo a opção de *type='Ljung-Box'*. Este teste pretende testar a seguinte hipótese nula:

$$H_0: \text{Não existe autocorrelação até ao lag } B \quad (3.15)$$

Sendo a estatística de teste dada por:

$$Q = n(n+2) \sum_{k=1}^m \frac{r_k^2}{n-k} \sim \chi^2_{1-\alpha, m-p-q} \quad (3.16)$$

onde m é o número de defasamentos considerados na função de autocorrelação, p e q as ordens do modelo ajustado e α o nível de significância considerado. A hipótese nula é rejeitada quando se tem $Q > \chi^2_{1-\alpha, m-p-q}$ ou $valor-p < \alpha$, sendo necessário testar um novo modelo.

Para verificar se os resíduos são normalmente distribuídos, será utilizado o teste de normalidade de *Shapiro-Wilk* (1965) [36], utilizando a função *shapiro.test* do R. Este teste pretende testar a seguinte hipótese nula:

$$H_0: \text{Os resíduos seguem uma distribuição Normal} \quad (3.17)$$

A hipótese nula não é rejeitada se $\text{valor-}p > \alpha$, sendo α o nível de significância escolhido, havendo então evidência estatística de que os resíduos não são normalmente distribuídos.

A fase de diagnóstico é muito importante na validação do modelo, se os resíduos seguirem uma distribuição aproximadamente normal e não forem correlacionados entre si, então o modelo considerado é adequado aos dados da série temporal em estudo, podendo ser utilizado para realizar a previsão de valores futuros.

4. Estimação dos Modelos e Análise de Resultados

Neste capítulo apresenta-se a análise descritiva de cada uma das séries temporais para os diversos tipos de transporte, bem como a sua modelação e previsão. Grande parte das séries em análise apresentam observações trimestrais, desde o primeiro trimestre de 2007 até ao quarto trimestre de 2017, havendo algumas exceções onde os dados apresentam um menor número de observações.

4.1. Transporte Aéreo

No transporte aéreo são consideradas duas séries com observações trimestrais desde 2007 a 2017 referentes a: movimento de passageiros no Aeroporto Internacional de Faro e movimento de passageiros entre o Aeroporto Internacional de Faro e outros aeroportos nacionais.

O Aeroporto Internacional de Faro é um aeroporto português pertencente à ANA Aeroportos de Portugal S.A. Hoje em dia, grande parte dos movimentos registados no Aeroporto Internacional de Faro deve-se ao aumento significativo dos voos *low cost*. Para fazer face ao aumento da procura, o aeroporto foi ampliado e modernizado nos últimos anos [43].

Em ambas as séries referidas são registados valores mais elevados nos meses de Verão (3º trimestre), o que leva a considerar a existência de sazonalidade uma vez que este pico da procura se repete anualmente.

4.1.1. Movimento de passageiros no Aeroporto Internacional de Faro

Análise Descritiva

O primeiro passo na análise de qualquer série temporal é a representação gráfica dos dados.




Figura 4.1: Movimento de Passageiros no Aeroporto Internacional de Faro de 2007 a 2017: (a) Observações trimestrais; (b) Observações anuais.

No gráfico da Figura 4.1 pode observar-se o aumento do movimento de passageiros ao longo dos anos, o que poderá evidenciar não estacionariedade da série temporal. O menor valor anual encontra-se em 2009, onde foram registados cerca de 5 milhões de passageiros. Pode ainda observar-se, no gráfico da Figura 4.1. a), um aumento significativo na diferença entre os valores do 1º e 3º trimestres, tendo havido uma variação de cerca de 1.4 milhões de passageiros em 2007 entre esses dois trimestres e de cerca de 2.6 milhões de passageiros em 2017. O crescimento anual verificado no número de passageiros poderá ser resultado, não só do aumento do movimento das companhias aéreas *low cost* e da abertura de novas rotas, mas também do forte aumento do turismo que se deve sobretudo ao aumento do terrorismo nos mercados competidores (Egipto, Tunísia, etc.).

Especificação do Modelo

De forma a verificar se a série é ou não estacionária, é aplicado o teste de estacionariedade de *Dickey-Fuller* Aumentado, onde se obtém um *valor - p* = 0.9879, o que leva a não rejeitar a hipótese nula de não estacionariedade da série temporal. É então necessário aplicar uma diferença não sazonal, $d = 1$, para tornar a série estacionária.




Figura 4.2: Diferenciação da série do Movimento de Passageiros no Aeroporto Internacional de Faro.

Após aplicar a diferenciação, verifica-se pelo gráfico da Figura 4.2 que a série temporal já se encontra estacionária na média. No entanto a variância é crescente ao longo do tempo, sendo necessário utilizar uma transformação de *Box-Cox* para estabilizar a variância dos dados. Utilizando a transformação logarítmica, na Figura 4.3 encontra-se o novo gráfico das primeiras diferenças.




Figura 4.3: Diferenciação da transformação logarítmica da série do Movimento de Passageiros no Aeroporto Internacional.

Após diferenciar a série temporal transformada, obtém-se uma série estacionária tanto na média como na variância, tal como se observa no gráfico da Figura 4.3. No entanto ainda é necessário remover a sazonalidade da série, para ser possível prosseguir à fase de identificação do modelo ARIMA sendo aplicada uma diferença sazonal, $D = 1$.

Estando a série estacionária em média e variância e sem efeito de sazonalidade, já é possível utilizar a metodologia de *Box & Jenkins*, sendo agora o objetivo encontrar um modelo ARIMA apropriado, através da análise da ACF e PACF representadas na Figura 4.4.




Figura 4.4: Função de Autocorrelação (a) e Autocorrelação Parcial (b) da série do Movimento de Passageiros no Aeroporto Internacional de Faro, sem tendência e sem sazonalidade.

O pico significativo no *lag* 1 na ACF sugere uma componente MA não-sazonal, $q = 1$, enquanto que o pico significativo no *lag* 1 na PACF sugere uma componente AR não-sazonal, $p = 1$, pelo que dois possíveis modelos de ajuste aos dados são:

- ✓ $ARIMA(0,1,1)(0,1,0)_4$ com um $AIC = -101.79$
- ✓ $ARIMA(1,1,0)(0,1,0)_4$ com um $AIC = -100.47$

Entre estes dois modelos possíveis, e tendo em conta o valor do AIC, é selecionado o modelo que apresenta um menor valor, ou seja, o modelo $ARIMA(0,1,1)(0,1,0)_4$.

Depois de ser selecionado um modelo de ajuste, é necessário proceder à fase de diagnóstico do modelo escolhido. Para tal são analisadas as características dos resíduos padronizados.

Diagnóstico do Modelo

No gráfico da Figura 4.5 estão representados os resíduos padronizados onde se pode observar que estes variam em torno de 0. No entanto, é importante investigar a existência de *outliers*, pois as observações relativas ao 1º trimestre de 2016 apresenta um valor residual fora do intervalo $[-3,3]$.




Figura 4.5: Resíduos Padronizados do modelo $ARIMA(0,1,1)(0,1,0)_4$ de ajuste à série do Movimento de Passageiros no Aeroporto Internacional de Faro.

Para as séries temporais distinguem-se dois tipos de *outliers*, do tipo aditivo (AO) e do tipo inovador (IO). Utilizando as funções *detectAO()* e *detectIO()* do pacote “TSA” [11] do R para o modelo $ARIMA(0,1,1)(0,1,0)_4$ obtido anteriormente, é detetado um *outlier* do tipo IO na observação 37, que

corresponde precisamente ao 1º trimestre de 2016, sendo significativo uma vez que $|\lambda_1| = 3.878492 > z_{0.975} = 1.96$. É obtido um novo modelo $ARIMA(0,1,1)(0,1,0)_4$, onde é incluído um regressor na observação 37, de forma a retirar o efeito desse *outlier* no modelo, obtendo-se um novo valor de $AIC = -106.74$.

De forma a verificar se o regressor incluído e os parâmetros do modelo considerado são estatisticamente significativos a um nível de significância de 5%, foi utilizada a função *coefest()* do pacote “lmtest” do R. Verifica-se que o parâmetro de médias móveis não sazonal não é significativo logo não deverá ser incluído no modelo. Passa-se então a ter o modelo $ARIMA(0,1,0)(0,1,0)_4$ sem a influência do *outlier* do tipo IO na observação 37, com um valor de $AIC = -107.31$, sendo este o melhor modelo de ajustamento aos dados em questão.

Procedendo mais uma vez à análise residual do modelo, no gráfico da Figura 4.6 estão representados os resíduos padronizados, onde se pode observar que os resíduos variam em torno de 0 e que já não existem observações discrepantes.




Figura 4.6: Resíduos Padronizados do modelo $ARIMA(0,1,0)(0,1,0)_4$ sem efeito do *outlier* detetado.

No gráfico da Figura 4.7 está representada a função de autocorrelação dos resíduos. Como se pode verificar não existe nenhum *lag* que exceda os limites de significância, logo nenhum deles apresenta autocorrelação estatisticamente significativa.




Figura 4.7: Função de Autocorrelação dos resíduos do modelo $ARIMA(0,1,0)(0,1,0)_4$ sem efeito do *outlier* detetado.

Aplicando o teste *Ljung-Box* para este modelo obtém-se um *valor-p*=0.9245, o que leva à não rejeição da hipótese nula de não existência de autocorrelação entre os resíduos até ao *lag* 20, que está de acordo com o observado no gráfico da função de autocorrelação.

Após estar confirmada a ausência de autocorrelação nos resíduos, é necessário testar a normalidade dos mesmos. Através do gráfico Q-Q representado na Figura 4.8, os resíduos aparentam seguir distribuição Normal.




Figura 4.8: Gráfico Quantil-Quantil dos resíduos do modelo $ARIMA(0,1,0)(0,1,0)_4$ sem efeito do *outlier* detetado.

Aplicando o teste de normalidade de *Shapiro-Wilk*, obtém-se um $\text{valor-}p=0.2787$ o que leva a que a hipótese de normalidade dos resíduos não seja rejeitada para qualquer nível de significância usual.

Pode-se então concluir que a série temporal em análise aparenta ser bem modelada pelo modelo $ARIMA(0,1,0)(0,1,0)_4$ sem influência do *outlier* detetado. Na Figura 4.9 encontra-se representado o gráfico do modelo ajustado e o gráfico da série original, onde é possível fazer uma comparação entre ambos.




Figura 4.9: Comparação entre a série do Movimento de Passageiros no Aeroporto Internacional de Faro e o modelo ajustado.

Previsão

Após realizado o diagnóstico dos resíduos, onde se verificou que o modelo $ARIMA(0,1,0)(0,1,0)_4$ sem influência do *outlier* detetado é um modelo adequado aos dados da série em estudo, pode-se então utilizá-lo para a previsão dos valores futuros, até 2020.

Prevê-se que o número de passageiros no Aeroporto Internacional de Faro continue a crescer até 2020, mas de forma mais suave comparativamente com o crescimento observado entre 2015 e 2017, tal como se pode observar no gráfico da Figura 4.10. Prevê-se ainda que atinja no 3º trimestre desse ano cerca de

4.1 milhões de passageiros, no entanto este valor não é muito preciso. Tal pode ser verificado através dos limites de previsão, que vão alargando, atingindo uma amplitude bastante elevada no ano de 2020, o que indica uma reduzida precisão da previsão. Os valores da previsão encontram-se na Tabela A.1 do Apêndice A.




Figura 4.10: Previsão do número de Passageiros no Aeroporto Internacional de Faro, entre 2018 e 2020.

4.1.2. Movimento de Passageiros entre o Aeroporto Internacional de Faro e outros Aeroportos Nacionais

Análise Descritiva

No gráfico da Figura 4.11 pode observar-se entre 2007 e 2017 uma tendência de aumento do número de passageiros, o que poderá evidenciar não estacionariedade da série temporal. Os menores valores anuais foram registados em 2007 e 2008, onde o número de passageiros foi cerca de 195 mil passageiros.

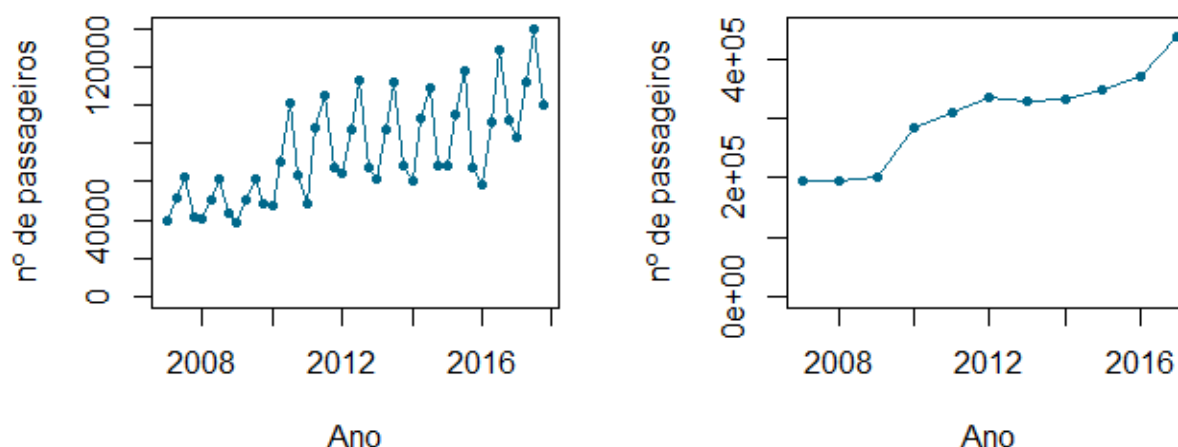


Figura 4.11: Movimento de Passageiros entre o Aeroporto Internacional de Faro e outros Aeroportos Nacionais entre 2007 e 2017: (a) Observações trimestrais; (b) Observações anuais.

Pode ainda observar-se, no gráfico da Figura 4.11. a), um aumento na amplitude sazonal da série entre 2009 e 2010, tendo havido uma variação de cerca de 23 mil passageiros em 2009 entre o 3º e o 1º trimestre, e de cerca de 54.8 mil passageiros em 2010, mantendo-se aproximadamente constante a partir daí.

O contínuo crescimento do número de passageiros poderá ser resultado do aumento do número de voos de Faro para Lisboa e Porto. A partir de 2010, a maior alteração verifica-se em termos do número de passageiros no 2º e 3º trimestres também devido ao aumento das ligações para Faro, sobretudo a partir de Lisboa, que captam os turistas que não vêm da Europa (Americanos, Asiáticos, etc.).

Especificação do Modelo

Uma vez que os dados trimestrais de 2007 a 2010 apresentam um padrão diferente dos restantes anos, optou-se por retirar estas observações para efeitos de estimação do modelo, para impedir que as mesmas influenciem de forma errada os valores de previsão.

Ao aplicar o teste de estacionariedade de *Dickey-Fuller* aos dados da série temporal sem as primeiras observações, obtém-se um *valor - p* = 0.5083, o que leva a não rejeitar a hipótese nula de não estacionariedade da série temporal, sendo necessário aplicar uma diferença não sazonal, $d = 1$, para tornar a série estacionária.




Figura 4.12: Diferenciação da série do Movimento de Passageiros entre o Aeroporto Internacional de Faro e outros Aeroportos Nacionais entre 2010 e 2017.

Tal como se pode observar no gráfico da Figura 4.12, após aplicar a diferenciação, a série temporal já se encontra estacionária tanto na média como na variância. No entanto ainda é necessário remover a sazonalidade da série, para ser possível prosseguir à fase de identificação do modelo ARIMA sendo, portanto, aplicada uma diferença sazonal, $D = 1$.

Estando a série estacionária em média e variância e sem efeito de sazonalidade, já é possível utilizar a metodologia de *Box & Jenkins*, sendo agora o objetivo encontrar um modelo ARIMA apropriado, através da análise da ACF e PACF representadas na Figura 4.13.




Figura 4.13: Função de Autocorrelação (a) e Autocorrelação Parcial (b) da série do Movimento de Passageiros entre o Aeroporto Internacional de Faro e outros Aeroportos Nacionais, sem tendência e sem sazonalidade.

O pico significativo no *lag* 4 na ACF sugere uma componente MA sazonal de ordem 1, $Q = 1$, enquanto que os picos significativos nos *lags* 4 e 8 na PACF sugerem uma componente AR sazonal de ordem 2, $P = 2$, pelo que dois modelos possíveis são:

- ✓ $ARIMA(0,1,0)(0,1,1)_4$ com um $AIC = 554.4$
- ✓ $ARIMA(0,1,0)(2,1,0)_4$ com um $AIC = 552.9$

Entre estes dois modelos, é seleccionado aquele que apresenta um menor valor de AIC, ou seja, o modelo $ARIMA(0,1,0)(2,1,0)_4$.

Depois de seleccionado um modelo de ajuste aos dados, é necessário proceder à fase de diagnóstico do mesmo. Para tal são analisadas as características dos resíduos padronizados.

Diagnóstico do Modelo

No gráfico da Figura 4.14 estão representados os resíduos padronizados onde se pode observar que estes variam em torno de 0, não havendo nenhuma informação discrepante, fora do intervalo $[-3,3]$.




Figura 4.14: Resíduos Padronizados do modelo $ARIMA(0,1,0)(2,1,0)_4$ de ajuste à série do Movimento de Passageiros entre o Aeroporto Internacional de Faro e outros Aeroportos Nacionais.

Para além disso, através da função *coefrest()* do R, verificou-se que o parâmetro autorregressivo sazonal de ordem 2 é estatisticamente significativo, logo pode ser incluído no modelo.

No gráfico da Figura 4.15 está representada a função de autocorrelação dos resíduos. Como se pode verificar não existe nenhum *lag* que exceda os limites de significância logo nenhum deles apresenta autocorrelação estatisticamente significativa.




Figura 4.15: Função de Autocorrelação dos resíduos do modelo $ARIMA(0,1,0)(2,1,0)_4$.

Aplicando o teste *Ljung-Box* para este modelo obtém-se um *valor - p* = 0.9917, o que leva à não rejeição da hipótese nula de não existência de autocorrelação entre os resíduos até ao *lag* 20, que está de acordo com o observado no gráfico da função de autocorrelação.

Após estar confirmada a ausência de autocorrelação nos resíduos, é necessário testar a normalidade dos mesmos. Através do gráfico Q-Q representado na Figura 4.16, os resíduos aparentam seguir distribuição Normal.




Figura 4.16: Gráfico Quantil-Quantil dos resíduos do modelo $ARIMA(0,1,0)(2,1,0)_4$.

Aplicando o teste de normalidade de *Shapiro-Wilk*, obtém-se um *valor - p* = 0.2114 o que leva a que a hipótese de normalidade dos resíduos não seja rejeitada para um nível de significância de 5%.

Pode-se então concluir que a série temporal em análise aparenta ser bem modelada pelo modelo $ARIMA(0,1,0)(2,1,0)_4$. Na Figura 4.17 encontra-se representado o gráfico do modelo ajustado e o gráfico da série original, onde é possível fazer uma comparação entre ambos.




Figura 4.17: Comparação entre a série do Movimento de Passageiros entre o Aeroporto Internacional de Faro e outros Aeroportos Nacionais e o modelo ajustado.

Previsão

Após realizado o diagnóstico dos resíduos, onde se verificou que o modelo $ARIMA(0,1,0)(2,1,0)_4$ é adequado aos dados da série do movimento de passageiros entre o Aeroporto Internacional de Faro e outros Aeroportos Nacionais, pode proceder-se à previsão até 2020.




Figura 4.18: Previsão do número de Passageiros entre o Aeroporto Internacional de Faro e outros Aeroportos Nacionais, de 2018 e 2020.

Prevê-se que o número de passageiros que utiliza o Aeroporto Internacional de Faro para viagens nacionais continue a crescer até 2020, e que registre no 3º trimestre desse ano cerca de 173 mil passageiros. Os valores da previsão encontram-se na Tabela A.2 do Apêndice A.

4.2. Transporte Coletivo Ferroviário

No transporte coletivo ferroviário serão analisadas duas séries com observações trimestrais desde 2007 a 2017: o movimento de passageiros no serviço regional e o movimento de passageiros no serviço de longo curso. Em ambas as séries são registados valores mais elevados nos meses de Verão (3º trimestre) diminuindo nos restantes trimestres. Estas oscilações repetem-se anualmente, tal como se pode verificar graficamente, o que leva a considerar a existência de sazonalidade.

4.2.1. Movimento de Passageiros no Serviço Regional

Análise Descritiva

No gráfico da Figura 4.19 observa-se uma acentuada diminuição na utilização anual do serviço regional ferroviário em cerca de 358.7 mil passageiros entre 2010 e 2012. A partir de 2012 a utilização deste serviço voltou a crescer, atingindo em 2017 um valor anual de cerca de 1.9 milhões de passageiros, semelhante aos valores que se registavam até 2010.




Figura 4.19: Movimento de Passageiros no Serviço Regional: (a) Observações trimestrais; (b) Observações anuais.

A diminuição que se observou até 2012 pode justificar-se devido à contínua degradação das condições do serviço prestado, face ao reduzido investimento neste modo de transporte, assistindo-se aos passageiros a optarem pela utilização do transporte individual. Acresce que, entre 2010 e 2012, se assistiu ao aumento do desemprego no País, sendo o Algarve a região do País com uma maior taxa de desemprego neste período, onde se registou uma taxa de desemprego de 13.4% em 2010 e de 17.6% em 2012 [33]. A partir de 2012 houve uma inversão da tendência, o número de passageiros que utilizam este serviço começou a aumentar ligeiramente, acontecimento que poderá ter resultado da crise económica e financeira, que induziu as pessoas à utilização do transporte coletivo ferroviário por ter um custo mais reduzido do que o transporte individual.

Especificação do Modelo

Uma vez que os dados trimestrais de 2007 apresentam um padrão diferente dos restantes anos, optou-se por retirar estas observações para efeitos de estimação do modelo, para impedir que as mesmas influenciem de forma errada os valores de previsão.

Teste de estacionariedade de *Dickey-Fuller*:

- ❖ $valor - p = 0.9481$: Não se rejeita a hipótese nula de não estacionariedade da série temporal, sendo necessário aplicar uma diferença não sazonal, $d = 1$, para tornar a série estacionária.




Figura 4.20: Diferenciação da série do Movimento de Passageiros no Serviço Regional Ferroviário, entre 2008 e 2017.

O gráfico da Figura 4.20 mostra que, após aplicar a diferenciação, a série temporal já se encontra estacionária tanto na média como na variância, sendo necessário remover a sazonalidade da série, aplicando uma diferença sazonal, $D = 1$.

Para determinação dos restantes parâmetros do modelo, serão analisados os gráficos da ACF e PACF da série livre de tendência e sazonalidade, representados na Figura 4.21.




Figura 4.21: Função de Autocorrelação (a) e Autocorrelação Parcial (b) da série do Movimento de Passageiros no Serviço Regional Ferroviário, sem tendência e sem sazonalidade.

O pico significativo no *lag* 4 na PACF sugere uma componente AR sazonal de ordem 1, $P = 1$. Poderá ainda ser considerado um modelo com uma componente sazonal MA de ordem 1, $Q = 1$, devido ao pico no *lag* 4 na ACF. Temos então dois possíveis modelos de estimação:

- ✓ $ARIMA(0,1,0)(1,1,0)_4$ com um $AIC = 798.85$
- ✓ $ARIMA(0,1,0)(0,1,1)_4$ com um $AIC = 797.82$

Tendo em conta o valor do AIC, é selecionado o modelo $ARIMA(0,1,0)(0,1,1)_4$, onde o parâmetro de médias móveis sazonal de ordem 1 é estatisticamente significativo, pelo que deverá estar incluído no modelo.

Diagnóstico do Modelo

No gráfico da Figura 4.22 estão representados os resíduos padronizados onde se pode observar que estes variam em torno de 0, não havendo nenhuma informação discrepante, fora do intervalo $[-3,3]$.




Figura 4.22: Resíduos Padronizados do modelo $ARIMA(0,1,0)(0,1,1)_4$ de ajuste à série do Movimento de Passageiros no Serviço Regional Ferroviário.

Depois da observação do gráfico dos resíduos, obtiveram-se os seguintes resultados para as hipóteses de autocorrelação e normalidade residual.

Teste de Autocorrelação de *Box-Ljung*:

- ❖ *valor* – $p = 0.8492$: Não se rejeita a hipótese nula, logo não existe autocorrelação entre os resíduos.

Teste de Normalidade de *Shapiro-Wilk*:

- ❖ *valor* – $p = 0.7075$: Não se rejeita a hipótese nula, logo os resíduos seguem aproximadamente uma distribuição Normal.

Pode-se então concluir que a série temporal em análise aparenta ser bem modelada pelo modelo $ARIMA(0,1,0)(0,1,1)_4$. Na Figura 4.23 encontra-se representado o gráfico do modelo ajustado e o gráfico da série original.




Figura 4.23: Comparação entre a série do Movimento de Passageiros no Serviço Regional Ferroviário e o modelo ajustado.

Previsão

Após realizado o diagnóstico dos resíduos, onde se verificou que o modelo $ARIMA(0,1,0)(0,1,1)_4$ é adequado aos dados da série do movimento de passageiros no serviço regional do transporte ferroviário, pode proceder-se à previsão até 2020.




Figura 4.24: Previsão do número de Passageiros no Serviço Regional Ferroviário, de 2018 e 2020.

Prevê-se que o número de passageiros que utiliza o serviço regional continue a crescer continuamente até 2020, e que registre no 3º trimestre desse ano cerca de 600 mil passageiros (Tabela B.1 do Apêndice B). No entanto esta previsão é pouco precisa, dada a elevada amplitude dos limites de previsão, tal como se pode verificar no gráfico da Figura 4.24.

4.2.2. Movimento de Passageiros no Serviço de Longo Curso

Análise Descritiva

No gráfico da Figura 4.25 observa-se uma ligeira diminuição na utilização do serviço de longo curso do transporte ferroviário em cerca de 97.4 mil passageiros entre 2009 e 2012. A partir de 2012, a utilização deste serviço voltou a crescer, atingindo em 2017 um valor anual de cerca de 870 mil passageiros.




Figura 4.25: Movimento de Passageiros no Serviço de Longo Curso: (a) Observações trimestrais; (b) Observações anuais.

O crescimento registado em termos dos passageiros no serviço de longo curso (serviços Alfa Pendular e Intercidades) poderá ter sido motivado pela crise económica e financeira. Com a crise, o preço dos combustíveis e portagens numa viagem de longo curso em transporte individual passou a ter um peso mais significativo no orçamento das famílias, pelo que o transporte ferroviário de longo curso passou a ser a melhor opção, designadamente para viagens entre Lisboa e Faro, por exemplo. Por outro lado, os turistas que chegam aos aeroportos do Porto e de Lisboa estão habituados a utilizar, nos seus países de origem, o transporte coletivo ferroviário, pelo que, com o crescimento do turismo, também esta opção passa a ter uma maior adesão pelo aumento da procura neste segmento.

Especificação do Modelo

Teste de estacionariedade de *Dickey-Fuller*:

- ❖ *valor - p* = 0.9414 : Não se rejeita a hipótese nula de não estacionariedade da série temporal, sendo necessário aplicar uma diferença não sazonal, $d = 1$, para tornar a série estacionária.




Figura 4.26: Diferenciação da série do Movimento de Passageiros no Serviço Ferroviário de Longo Curso.

O gráfico da Figura 4.26 mostra que, após aplicar a diferenciação, a série temporal já se encontra estacionária tanto na média como na variância, sendo necessário ainda remover a sazonalidade da série, aplicando uma diferença sazonal, $D = 1$.

Para determinação dos restantes parâmetros do modelo, serão analisados os gráficos da ACF e PACF da série livre de tendência e sazonalidade, representados na Figura 4.27.




Figura 4.27: Função de Autocorrelação (a) e Autocorrelação Parcial (b) da série do Movimento de Passageiros no Serviço Ferroviário de Longo Curso, sem tendência e sem sazonalidade.

O pico significativo no *lag* 1 na ACF sugere uma componente MA não-sazonal de ordem 1, $q = 1$, enquanto que os picos significativos nos *lags* 1 e 2 na PACF sugerem uma componente AR não sazonal de ordem 2, $p = 2$. Temos então dois possíveis modelos de estimação:

- ✓ $ARIMA(0,1,1)(0,1,0)_4$ com um $AIC = 826.59$
- ✓ $ARIMA(2,1,0)(0,1,0)_4$ com um $AIC = 824.02$

Tendo em conta o valor do AIC, é selecionado o modelo $ARIMA(2,1,0)(0,1,0)_4$, onde o parâmetro autorregressivo não sazonal de ordem 2 é estatisticamente significativo, devendo permanecer no modelo.

Diagnóstico do Modelo

No gráfico da Figura 4.28 estão representados os resíduos padronizados onde se pode observar que os resíduos variam em torno de 0, não havendo nenhuma informação discrepante, fora do intervalo $[-3,3]$.




Figura 4.28: Resíduos Padronizados do modelo $ARIMA(2,1,0)(0,1,0)_4$ de ajuste à série do Movimento de Passageiros no Serviço Ferroviário de Longo Curso.

Depois da observação do gráfico dos resíduos, obtiveram-se os seguintes resultados para as hipóteses de autocorrelação e normalidade residual:

Teste de Autocorrelação de *Box-Ljung*:

- ❖ *valor* – $p = 0.5919$: Não se rejeita a hipótese nula, logo não existe autocorrelação entre os resíduos.

Teste de Normalidade de *Shapiro-Wilk*:

- ❖ *valor* – $p = 0.7914$: Não se rejeita a hipótese nula, logo os resíduos seguem aproximadamente uma distribuição Normal.

Pode-se então concluir que a série temporal em análise aparenta ser bem modelada pelo modelo $ARIMA(2,1,0)(0,1,0)_4$. Na Figura 4.29 encontra-se representado o gráfico do modelo ajustado e o gráfico da série original.




Figura 4.29: Comparação entre a série do Movimento de Passageiros no Serviço de Longo Curso e o modelo ajustado.

Previsão

Após realizado o diagnóstico dos resíduos, onde se verificou que o modelo $ARIMA(2,1,0)(0,1,0)_4$ é adequado aos dados da série do movimento de passageiros no serviço de longo curso do transporte coletivo ferroviário, pode proceder-se à previsão até 2020.

Prevê-se que o número de passageiros que utiliza o serviço de longo curso do transporte ferroviário continue a crescer continuamente até 2020, tal como se pode observar no gráfico da Figura 4.30, e que registre no 3º trimestre desse ano cerca de 375 mil passageiros. Neste caso, a amplitude dos limites de previsão a 95% não é muito grande, pelo que se pode concluir que a previsão obtida possui uma precisão elevada. A previsão obtida para os valores de 2018 a 2020 encontram-se na Tabela B.2 do Apêndice B.




Figura 4.30: Previsão do número de Passageiros no Serviço de Longo Curso, de 2018 a 2020.

4.3. Transporte Fluvial/Marítimo

No transporte fluvial e marítimo são analisadas duas séries com observações trimestrais desde 2007 até 2017: o movimento de passageiros na carreira do Guadiana, com percurso entre Vila Real de Santo António e Ayamonte, e o movimento de passageiros nas carreiras da Ria Formosa. Em ambas as séries são registados valores mais elevados nos meses de Verão (3º trimestre) diminuindo nos restantes trimestres. Estas oscilações repetem-se anualmente, tal como se pode verificar graficamente, o que leva a considerar a existência de sazonalidade.

4.3.1. Movimento de Passageiros no Guadiana (Vila Real de Santo António – Ayamonte)

Análise Descritiva




Figura 4.31: Movimento de Passageiros do Guadiana (Vila Real de Santo António – Ayamonte): (a) Observações trimestrais; (b) Observações anuais.

No gráfico da Figura 4.31 observa-se uma acentuada diminuição na utilização da carreira do Guadiana em cerca de 66.6 mil passageiros entre 2007 e 2013. A partir de 2013, a utilização desta carreira voltou a crescer, devido sobretudo a questões relacionadas com o turismo, atingindo em 2017 um valor anual de cerca de 140.5 mil passageiros. No entanto, este crescimento ainda não foi suficiente para atingir os valores próximos de 180 mil passageiros que se verificavam em 2007.

Especificação do Modelo

Teste de estacionariedade de *Dickey-Fuller*:

- ❖ $\text{valor} - p = 0.9093$: Não se rejeita a hipótese nula de não estacionariedade da série temporal, sendo necessário aplicar uma diferença não sazonal, $d = 1$, para tornar a série estacionária.

O gráfico da Figura 4.32 mostra que após aplicar a diferenciação a série temporal já se encontra estacionária tanto na média como na variância, sendo necessário remover a sazonalidade da série, aplicando uma diferença sazonal, $D = 1$.




Figura 4.32: Diferenciação da série do Movimento de Passageiros do Guadiana (Vila Real de Santo António – Ayamonte).

Para determinação dos restantes parâmetros do modelo, serão analisados os gráficos da ACF e PACF da série livre de tendência e sazonalidade, representados na Figura 4.33.




Figura 4.33: Função de Autocorrelação (a) e Autocorrelação Parcial (b) da série do Movimento de Passageiros do Guadiana, sem tendência e sem sazonalidade.

O pico significativo no *lag* 1 na ACF sugere uma componente MA não-sazonal de ordem 1, $q = 1$, enquanto que os picos significativos nos *lags* 1 e 4 na PACF sugerem uma componente AR não sazonal de ordem 1, $p = 1$, e uma sazonal também de ordem 1, $P = 1$.

Temos então dois possíveis modelos de estimação:

- ✓ $ARIMA(0,1,1)(0,1,0)_4$ com um $AIC = 736.77$
- ✓ $ARIMA(1,1,0)(1,1,0)_4$ com um $AIC = 741.41$

Tendo em conta o valor do AIC, é seleccionado o modelo $ARIMA(0,1,1)(0,1,0)_4$, em que o parâmetro de médias móveis não sazonal de ordem 1 é estatisticamente significativo, logo deverá ser incluído no modelo.

Diagnóstico do Modelo

No gráfico da Figura 4.34 estão representados os resíduos padronizados onde se pode observar que os resíduos variam em torno de 0, não havendo nenhuma informação discrepante, fora do intervalo $[-3,3]$.




Figura 4.34: Resíduos Padronizados do modelo $ARIMA(0,1,1)(0,1,0)_4$ de ajuste à série do Movimento de Passageiros do Guadiana.

Depois da observação do gráfico dos resíduos, obtiveram-se os seguintes resultados para as hipóteses de autocorrelação e normalidade residual.

Teste de Autocorrelação de *Box-Ljung*:

- ❖ *valor – p* = 0.4771 : Não se rejeita a hipótese nula, logo não existe autocorrelação entre os resíduos.

Teste de Normalidade de *Shapiro-Wilk*:

- ❖ *valor – p* = 0.3219: Não se rejeita a hipótese nula, logo os resíduos seguem aproximadamente uma distribuição Normal.

Pode-se então concluir que a série temporal em análise aparenta ser bem modelada pelo modelo $ARIMA(0,1,1)(0,1,0)_4$. Na Figura 4.35 encontra-se representado o gráfico do modelo ajustado e o gráfico da série original.




Figura 4.35: Comparação entre a série do Movimento de Passageiros do Guadiana e o modelo ajustado.

Previsão

Após realizado o diagnóstico dos resíduos, onde se verificou que o modelo $ARIMA(0,1,1)(0,1,0)_4$ é adequado aos dados da série do movimento de passageiros do Guadiana, pode proceder-se à previsão até 2020.




Figura 4.36: Previsão do número de passageiros do Guadiana, de 2018 e 2020.

Prevê-se que o número de passageiros que utiliza a carreira do Guadiana continue a crescer até 2020, e que registe no 3º trimestre desse ano cerca de 72 mil passageiros (Tabela C.1 do Apêndice C). Neste caso, como se verifica no gráfico da Figura 4.35, o modelo escolhido apresenta um bom ajuste aos dados, pelo que a previsão obtida tem uma precisão elevada, visível na pequena amplitude dos limites de previsão, na Figura 4.36.

4.3.2. Movimento de Passageiros na Ria Formosa

Relativamente ao movimento de passageiros em transporte fluvial na Ria Formosa, os dados disponíveis revelaram-se insuficientes, em alguns casos apenas traduzindo a procura de passageiros para alguns trimestres do ano. Por outro lado, com o crescimento do turismo, foram surgindo novas carreiras e serviços ao longo dos últimos anos e que interessaria também contabilizar. Assim, dada a necessidade de organizar uma recolha sistemática adequada e de qualidade para os dados da mobilidade fluvial na Ria Formosa, a par da atualização necessária dos serviços de transporte, optou-se por não realizar a previsão desta série temporal, realizando-se apenas a análise gráfica visando obter indicadores básicos sobre a evolução da mesma.

Análise Descritiva

No gráfico da Figura 4.37, observa-se um crescimento na utilização anual das carreiras da Ria Formosa em cerca de 530 mil passageiros desde 2015.




Figura 4.37: Movimento de Passageiros nas carreiras da Ria Formosa: (a) Observações trimestrais; (b) Observações anuais.

A variação anual observada deve-se principalmente às alterações registadas no 3º trimestre, o que seria de esperar uma vez que muitas das carreiras da Ria Formosa fazem percursos até Ilhas que apenas são requisitadas nos meses de verão.

4.4. Transporte Coletivo Rodoviário

No transporte coletivo rodoviário é analisada a série do movimento de passageiros nas ligações urbanas com observações trimestrais desde 2011 a 2017, e as séries do movimento de passageiros nas ligações inter-urbanas, inter-regionais e internacionais, com observações trimestrais desde 2007 a 2017.

4.4.1. Movimento de Passageiros nas Ligações Urbanas

Análise Descritiva

No gráfico da Figura 4.38 observa-se, entre 2011 e 2013, uma acentuada diminuição na utilização das ligações urbanas do transporte coletivo rodoviário, em cerca de 2.3 milhões de passageiros anuais. A partir de 2013 a série mantém um comportamento aproximadamente constante.




Figura 4.38: Movimento de Passageiros nas Ligações Urbanas: (a) Observações trimestrais; (b) Observações anuais.

Especificação do Modelo

Teste de estacionariedade de *Dickey-Fuller*:

- ❖ $\text{valor} - p = 0.3701$: Não se rejeita a hipótese nula de não estacionariedade da série temporal, sendo necessário aplicar uma diferença não sazonal, $d = 1$, para tornar a série estacionária.




Figura 4.39: Diferenciação da série do Movimento de Passageiros nas Ligações Urbanas.

O gráfico da Figura 4.39 mostra que após aplicar a diferenciação a série temporal já se encontra estacionária tanto na média como na variância, sendo necessário remover a sazonalidade da série, aplicando uma diferença sazonal, $D = 1$.

Para determinação dos restantes parâmetros do modelo, serão analisados os gráficos da ACF e PACF da série livre de tendência e sazonalidade, representados na figura 4.38.




Figura 4.40: Função de Autocorrelação (a) e Autocorrelação Parcial (b) da série do Movimento das Ligações Urbanas.

O pico significativo no *lag* 4 na PACF sugere uma componente AR sazonal de ordem 1, $P = 1$. Poderá ainda ser considerado um modelo com uma componente sazonal MA de ordem 1, $Q = 1$, devido ao pico no *lag* 4 na ACF. Temos então dois possíveis modelos de estimação:

- ✓ $ARIMA(0,1,0)(1,1,0)_4$ com um $AIC = 586.37$
- ✓ $ARIMA(0,1,0)(0,1,1)_4$ com um $AIC = 586.66$

Tendo em conta o valor do AIC, é selecionado o modelo $ARIMA(0,1,0)(1,1,0)_4$, onde o parâmetro autorregressivo sazonal de ordem 1 é estatisticamente significativo logo deverá permanecer no modelo.

Diagnóstico do Modelo

No gráfico da Figura 4.41 estão representados os resíduos padronizados onde se pode observar que os resíduos variam em torno de 0. No entanto será vantajoso investigar a existência de *outliers*, pois a observação relativa ao 1º trimestre de 2013 apresenta um valor residual mais elevado, com valor absoluto superior a 3.




Figura 4.41: Resíduos Padronizados do modelo $ARIMA(0,1,0)(1,1,0)_4$ de ajuste à série do Movimento de Passageiros das ligações Urbanas.

Utilizando as funções *detectAO()* e *detectIO()* do R para o modelo $ARIMA(0,1,0)(1,1,0)_4$ obtido anteriormente, é detectado um *outlier* do tipo IO na observação 9, correspondente ao 1º trimestre de 2013, sendo significativo uma vez que $|\lambda_1| = 3.704382 > z_{0,975} = 1.96$. É obtido um novo modelo $ARIMA(0,1,0)(1,1,0)_4$, onde é incluído um regressor na observação 9, de forma a retirar o efeito desse *outlier* no modelo, obtendo-se um novo valor de $AIC = 583.83$.

Procedendo mais uma vez à análise residual do modelo, no gráfico da Figura 4.42 estão representados os resíduos padronizados onde se pode observar que os resíduos variam em torno de 0, e já não se verifica a existência observações discrepantes.




Figura 4.42: Resíduos Padronizados do modelo $ARIMA(0,1,0)(1,1,0)_4$ sem efeito do *outlier* detetado.

Depois da observação do gráfico dos resíduos, obtiveram-se os seguintes resultados para as hipóteses de autocorrelação e normalidade residual.

Teste de Autocorrelação de *Box-Ljung*:

- ❖ *valor* – $p = 0.918$: Não se rejeita a hipótese nula, logo não existe autocorrelação entre os resíduos.

Teste de Normalidade de *Shapiro-Wilk*:

- ❖ *valor* – $p = 0.754$: Não se rejeita a hipótese nula, logo os resíduos seguem aproximadamente uma distribuição Normal.

Pode-se então concluir que a série temporal em análise aparenta ser bem modelada pelo modelo $ARIMA(0,1,0)(1,1,0)_4$ sem influencia do *outlier* detetado. Na Figura 4.43 encontra-se representado o gráfico do modelo ajustado e o gráfico da série original.




Figura 4.43: Comparação entre a série Movimento de Passageiros das ligações Urbanas e o modelo ajustado.

Relativamente ao modelo de ajuste selecionado verifica-se, através do gráfico da Figura 4.43, que este acaba por se afastar um pouco do comportamento da série temporal em questão. Neste caso, a dificuldade em encontrar um modelo adequado aos dados poderá ser consequência de apenas serem considerados 7 anos na estimação do modelo, ou seja, 28 observações.

Previsão

Após realizado o diagnóstico dos resíduos, onde todas as hipóteses foram verificadas, pode proceder-se à previsão até 2020.

Prevê-se que o número de passageiros que utiliza as ligações urbanas do transporte coletivo rodoviário tenha um comportamento ligeiramente decrescente até 2020, como se pode verificar no gráfico da Figura 4.44. Neste caso, como consequência do fraco ajuste do modelo escolhido a previsão tem uma precisão muito baixa, tal como era de esperar, uma vez que utilizar apenas 7 anos para prever os 3 anos futuros leva a uma grande incerteza associadas aos resultados que se obtém. Os valores da previsão encontram-se na Tabela D.1 do Apêndice D.




Figura 4.44: Previsão do número de Passageiros que utiliza as ligações Urbanas, de 2018 e 2020.

4.4.2. Movimento de Passageiros nas Ligações Inter-Urbanas

Análise Descritiva

No gráfico da Figura 4.45 observa-se uma diminuição contínua do movimento de passageiros nas ligações inter-urbanas, envolvendo uma redução total de cerca de 3.16 milhões de passageiros, entre 2007 e 2014. A partir de 2014, a série apresenta um comportamento aproximadamente constante, mantendo-se em valores muito inferiores aos que se registavam em 2007.




Figura 4.45: Movimento de Passageiros nas Ligações Inter-Urbanas: (a) Observações trimestrais; (b) Observações anuais.

As carreiras inter-urbanas apresentam um comportamento diferente dos restantes modos de transporte já analisados para a região do Algarve, já que os valores mais baixos são sempre registados no 3º trimestre acabando por aumentar nos restantes trimestres. O transporte coletivo rodoviário inter-urbano é utilizado maioritariamente pelos residentes locais e pelos estudantes, pelo que é esperado que a sua utilização diminua no verão. Por outro lado, dado o novo regime jurídico do serviço público do transporte de passageiros (Lei nº 52/2015, de 9 de junho) [15], espera-se também uma nova organização do mercado de transporte coletivo em Portugal, com a alteração do modelo institucional de planeamento e gestão.

Especificação do Modelo

Teste de estacionariedade de *Dickey-Fuller*:

- ❖ $\text{valor} - p = 0.7477$: Não se rejeita a hipótese nula de não estacionariedade da série temporal, sendo necessário aplicar uma diferença não sazonal, $d = 1$, para tornar a série estacionária.




Figura 4.46: Diferenciação da série do Movimento de Passageiros nas Ligações Inter-Urbanas.

O gráfico da Figura 4.46 mostra que, após aplicar a diferenciação, a série temporal já se encontra estacionária tanto na média como na variância, sendo necessário remover a sazonalidade da série, aplicando uma diferença sazonal, $D = 1$.

Para determinação dos restantes parâmetros do modelo, serão analisados os gráficos da ACF e PACF da série livre de tendência e sazonalidade, representados na Figura 4.47.




Figura 4.47: Função de Autocorrelação (a) e Autocorrelação Parcial (b) da série do Movimento das ligações Inter-Urbanas.

Os picos significativos nos *lags* 1 e 4 na ACF sugerem uma componente MA não-sazonal de ordem 1, $q = 1$, e uma sazonal também de ordem 1, $Q = 1$. Na PACF, os picos significativos nos *lags* 1 e 2 sugerem uma componente AR não-sazonal de ordem 2, $p = 2$, e o pico no *lag* 4 uma componente sazonal de ordem 1, $P = 1$. Temos então dois possíveis modelos de estimação:

- ✓ $ARIMA(0,1,1)(0,1,1)_4$ com um $AIC = 983.45$
- ✓ $ARIMA(2,1,0)(1,1,0)_4$ com um $AIC = 980.73$

Tendo em conta o valor do AIC, é selecionado o modelo $ARIMA(2,1,0)(1,1,0)_4$. No entanto o parâmetro autorregressivo não-sazonal de ordem 2 não é significativo logo deverá ser eliminado. Passa-se então a ter o modelo $ARIMA(1,1,0)(1,1,0)_4$, com um valor de $AIC = 979.53$, sendo este o melhor modelo de ajustamento aos dados em questão.

Diagnóstico do Modelo

No gráfico da Figura 4.48 estão representados os resíduos padronizados onde se pode observar que os resíduos variam em torno de 0, não havendo nenhuma informação discrepante, fora do intervalo $[-3,3]$.




Figura 4.48: Resíduos Padronizados do modelo $ARIMA(1,1,0)(1,1,0)_4$ de ajuste à série do Movimento de Passageiros das ligações Inter-Urbanas.

Depois da observação do gráfico dos resíduos, obtiveram-se os seguintes resultados para as hipóteses de autocorrelação e normalidade residual.

Teste de Autocorrelação de *Box-Ljung*:

- ❖ $\text{valor} - p = 0.334$: Não se rejeita a hipótese nula, logo não existe autocorrelação entre os resíduos.

Teste de Normalidade de *Shapiro-Wilk*:

- ❖ $\text{valor} - p = 0.6339$: Não se rejeita a hipótese nula, logo os resíduos seguem aproximadamente uma distribuição Normal.

Pode-se então concluir que a série temporal em análise aparenta ser bem modelada pelo modelo $ARIMA(1,1,0)(1,1,0)_4$. Na Figura 4.49 encontra-se representado o gráfico do modelo ajustado e o gráfico da série original.




Figura 4.49: Comparação entre a série Movimento de Passageiros das ligações Inter-Urbanas e o modelo ajustado.

Previsão

Após realizado o diagnóstico dos resíduos, onde se verificou que o modelo $ARIMA(1,1,0)(1,1,0)_4$ é adequado aos dados da série do movimento de passageiros nas ligações inter-urbanas, pode proceder-se à previsão até 2020.




Figura 4.50: Previsão do número de Passageiros das ligações Inter-Urbanas, de 2018 e 2020.

Prevê-se que o número de passageiros que utiliza as ligações inter-urbanas do transporte coletivo rodoviário se mantenha aproximadamente constante até 2020, continuando com as oscilações sazonais, onde os valores mais baixos voltarão a registrar-se no 3º trimestre. Os valores da previsão encontram-se na Tabela D.2 do Apêndice D.

4.4.3. Movimento de Passageiros nas Ligações Inter-Regionais

Análise Descritiva

No gráfico da Figura 4.51 verifica-se que o movimento de passageiros nas ligações inter-regionais sofreu algumas oscilações entre 2007 e 2013. A partir de 2013 o comportamento foi crescente até 2017, sendo a variação total neste período cerca de 117 mil passageiros. Pode ainda observar-se, no gráfico da Figura 4.51 a), um aumento significativo na diferença na amplitude sazonal da série, tendo havido uma variação de cerca de 139 mil passageiros em 2007 entre o 1º e o 3º trimestre e de cerca de 214 mil passageiros em 2017.

O crescimento registado, anteriormente referido, poderá ter sido provocado pela crise. A redução dos salários e o aumento do desemprego, acompanhados do preço elevado dos combustíveis e portagens, levou a que o transporte individual deixasse de ser uma opção viável para viagens mais longas, levando então ao aumento da utilização do transporte coletivo rodoviário nas ligações inter-regionais, também por ser uma alternativa mais económica que o transporte ferroviário.




Figura 4.51: Movimento de Passageiros nas Ligações Inter-Regionais: (a) Observações trimestrais; (b) Observações anuais.

Especificação do Modelo

Teste de estacionariedade de *Dickey-Fuller*:

- ❖ *valor – p* = 0.7754: Não se rejeita a hipótese nula de não estacionariedade da série temporal, sendo necessário aplicar uma diferença não sazonal, $d = 1$, para tornar a série estacionária.




Figura 4.52: Diferenciação da série do Movimento de Passageiros nas Ligações Inter-Regionais.

O gráfico da Figura 4.52 mostra que, após aplicar a diferenciação, a série temporal já se encontra estacionária tanto na média como na variância, sendo necessário remover a sazonalidade da série, aplicando uma diferença sazonal, $D = 1$.

Para determinação dos restantes parâmetros do modelo, serão analisados os gráficos da ACF e PACF da série livre de tendência e sazonalidade, representados na Figura 4.53.

O pico significativo no *lag* 1 na ACF sugere um modelo com uma componente MA não-sazonal de ordem 1, $q = 1$, enquanto que o pico significativo no *lag* 1 da PACF sugere uma componente AR não-sazonal de ordem 1, $p = 1$. Temos então dois possíveis modelos de estimação:

- ✓ $ARIMA(0,1,1)(0,1,0)_4$ com um $AIC = 834.63$
- ✓ $ARIMA(1,1,0)(0,1,0)_4$ com um $AIC = 835.66$




Figura 4.53: Função de Autocorrelação (a) e Autocorrelação Parcial (b) da série do Movimento das ligações Inter-Regionais.

Tendo em conta o valor do AIC, é seleccionado o modelo $ARIMA(0,1,1)(0,1,0)_4$, sendo este o melhor modelo de ajustamento aos dados em questão. Como o parâmetro de médias móveis não sazonal é estatisticamente significativo, este não deverá ser retirado do modelo.

Diagnóstico do Modelo

No gráfico da Figura 4.54 estão representados os resíduos padronizados onde se pode observar que os resíduos variam em torno de 0, não havendo nenhuma informação discrepante, fora do intervalo $[-3,3]$.




Figura 4.54: Resíduos Padronizados do modelo $ARIMA(0,1,1)(0,1,0)_4$ de ajuste à série do Movimento de Passageiros das ligações Inter-Regionais.

Depois da observação do gráfico dos resíduos, obtiveram-se os seguintes resultados para as hipóteses de autocorrelação e normalidade residual.

Teste de Autocorrelação de *Box-Ljung*:

- ❖ *valor – p* = 0.7572 : Não se rejeita a hipótese nula, logo não existe autocorrelação entre os resíduos.

Teste de Normalidade de *Shapiro-Wilk*:

- ❖ *valor – p* = 0.1768: Não se rejeita a hipótese nula, logo os resíduos seguem aproximadamente uma distribuição Normal.

Pode-se então concluir que a série temporal em análise aparenta ser bem modelada pelo modelo $ARIMA(0,1,1)(0,1,0)_4$. Na Figura 4.55 encontra-se representado o gráfico do modelo ajustado e o gráfico da série original.




Figura 4.55: Comparação entre a série do Movimento de Passageiros das ligações Inter-Regionais e o modelo ajustado.

Previsão

Após realizado o diagnóstico dos resíduos, onde se verificou que o modelo $ARIMA(0,1,1)(0,1,0)_4$ é adequado aos dados da série do movimento de passageiros nas ligações inter-regionais, pode proceder-se à previsão até 2020.

Prevê-se que o número de passageiros que utiliza as ligações inter-regionais do transporte coletivo rodoviário continue a crescer até 2020, tal como se pode observar na Figura 4.56, atingindo um valor próximo de 417 mil de passageiros no 3º trimestre de 2020 (Tabela D.3 do Apêndice D).




Figura 4.56: Previsão do número de Passageiros que utiliza as ligações Inter-Regionais, de 2018 e 2020.

4.4.4. Movimento de Passageiros nas Ligações Internacionais

Análise Descritiva

Através da Figura 4.57, verifica-se que, no geral, o movimento de passageiros nas ligações internacionais teve uma variação positiva entre 2007 e 2015, começando a diminuir a partir desse mesmo ano.




Figura 4.57: Movimento de Passageiros nas Ligações Internacionais: (a) Observações trimestrais; (b) Observações anuais.

Essa diminuição, tal como se pode verificar no gráfico das observações trimestrais, deveu-se essencialmente à diminuição do número de passageiros no segundo e terceiro trimestres, que poderá estar associada ao aumento da utilização do transporte aéreo para viagens internacionais.

Especificação do Modelo

Teste de estacionariedade de *Dickey-Fuller*:

- ❖ *valor - p* = 0.9872: Não se rejeita a hipótese nula de não estacionariedade da série temporal, sendo necessário aplicar uma diferença não sazonal, $d = 1$, para tornar a série estacionária.




Figura 4.58: Diferenciação da série do Movimento de Passageiros nas Ligações Internacionais.

O gráfico da Figura 4.58 mostra que, após aplicar a diferenciação, a série temporal já se encontra estacionária tanto na média como na variância, sendo necessário remover a sazonalidade da série, aplicando uma diferença sazonal, $D = 1$.

Para determinação dos restantes parâmetros do modelo, serão analisados os gráficos da ACF e PACF da série livre de tendência e sazonalidade, representados na Figura 4.59.




Figura 4.59: Função de Autocorrelação (a) e Autocorrelação Parcial (b) da série do Movimento das ligações Internacionais.

O pico significativo no *lag* 1 na ACF sugere um modelo com uma componente MA não-sazonal de ordem 1, $q = 1$, enquanto que os picos significativos nos *lags* 1 e 2 da PACF sugerem uma componente AR não-sazonal de ordem 2, $p = 2$. Temos então dois possíveis modelos de estimação:

- ✓ $ARIMA(0,1,1)(0,1,0)_4$ com um $AIC = 616.69$
- ✓ $ARIMA(2,1,0)(0,1,0)_4$ com um $AIC = 625.60$

Tendo em conta o valor do AIC, é selecionado o modelo $ARIMA(0,1,1)(0,1,0)_4$, sendo este o melhor modelo de ajustamento aos dados em questão. Como o parâmetro de médias móveis não sazonal é estatisticamente significativo, este não deverá ser retirado do modelo.

Diagnóstico do Modelo

No gráfico da Figura 4.60 estão representados os resíduos padronizados onde se pode observar que os resíduos variam em torno de 0, não havendo nenhuma informação discrepante, fora do intervalo $[-3,3]$.




Figura 4.60: Resíduos Padronizados do modelo $ARIMA(0,1,1)(0,1,0)_4$ de ajuste à série do Movimento de Passageiros das ligações Internacionais.

Depois da observação do gráfico dos resíduos, obtiveram-se os seguintes resultados para as hipóteses de autocorrelação e normalidade residual.

Teste de Autocorrelação de *Box-Ljung*:

- ❖ *valor* – $p = 0.3796$: Não se rejeita a hipótese nula, logo não existe autocorrelação entre os resíduos.

Teste de Normalidade de *Shapiro-Wilk*:

- ❖ *valor* – $p = 0.431$: Não se rejeita a hipótese nula, logo os resíduos seguem aproximadamente uma distribuição Normal.

Pode-se então concluir que a série temporal em análise aparenta ser bem modelada pelo modelo $ARIMA(0,1,1)(0,1,0)_4$. Na Figura 4.61 encontra-se representado o gráfico do modelo ajustado e o gráfico da série original.




Figura 4.61: Comparação entre a série Movimento de Passageiros das ligações Internacionais e o modelo ajustado.

Previsão

Após realizado o diagnóstico dos resíduos, onde se verificou que o modelo $ARIMA(0,1,1)(0,1,0)_4$ é adequado aos dados da série do movimento de passageiros nas ligações internacionais, pode proceder-se à previsão até 2020.




Figura 4.62: Previsão do número de Passageiros que utiliza as ligações Internacionais, de 2018 e 2020.

Prevê-se, com um grau de precisão elevado, que o número de passageiros que utiliza as ligações internacionais do transporte coletivo rodoviário se mantenha aproximadamente constante até 2020. Os valores da previsão encontram-se em Apêndice.

4.5. Transporte Rodoviário na Rede Rodoviária Principal

No transporte Rodoviário são analisadas três séries com observações trimestrais desde 2007 a 2017: o Tráfego Médio Diário na autoestrada A2 (Almodôvar - São Bartolomeu de Messines), na Ponte Internacional do Guadiana e na autoestrada A22.

4.5.1. Tráfego Médio Diário na Autoestrada A2 (Almodôvar/São Bartolomeu de Messines)

Análise Descritiva

Pela Figura 4.63, verifica-se que o tráfego médio diário na A2 sofreu um grande decréscimo no seu valor anual entre 2009 e 2012 em cerca de 49 mil veículos/dia. Após 2013 o tráfego médio diário foi crescendo gradualmente até 2017, voltando a atingir valores próximos aos registados antes de 2009. O menor valor anual foi registado em 2012 e 2013, um tráfego médio diário de cerca de 92 mil veículos/dia.




Figura 4.63: Tráfego Médio Diário na A2 (Almodôvar/São Bartolomeu de Messines): (a) Observações trimestrais; (b) Observações anuais.

Especificação do Modelo

Teste de estacionariedade de *Dickey-Fuller*:

- ❖ $\text{valor} - p = 0.9534$: Não se rejeita a hipótese nula de não estacionariedade da série temporal, sendo necessário aplicar uma diferença não sazonal, $d = 1$, para tornar a série estacionária.




Figura 4.64: Diferenciação da série do Tráfego Médio Diário na A2 (Almodôvar/São Bartolomeu de Messines).

O gráfico da Figura 4.64 mostra que, após aplicar a diferenciação, a série temporal já se encontra estacionária tanto na média como na variância, sendo necessário remover a sazonalidade da série, aplicando uma diferença sazonal, $D = 1$.

Para determinação dos restantes parâmetros do modelo, serão analisados os gráficos da ACF e PACF da série livre de tendência e sazonalidade, representados na Figura 4.65.




Figura 4.65: Função de Autocorrelação (a) e Autocorrelação Parcial (b) da série Tráfego Médio Diário na A2.

Não se observam picos significativos nos gráficos da ACF e da PACF, podendo considerar-se um modelo sem parâmetros autorregressivo e de médias móveis sazonal e não sazonal. Temos então o seguinte possível modelo de estimação:

✓ $ARIMA(0,1,0)(0,1,0)_4$ com um $AIC = 635.52$

Diagnóstico do Modelo

No gráfico da Figura 4.66 estão representados os resíduos padronizados onde se pode observar que os resíduos variam em torno de 0. No entanto será vantajoso investigar a existência de *outliers*, pois a observação relativa ao 2º trimestre de 2019 apresenta um valor residual mais elevado.




Figura 4.66: Resíduos Padronizados do modelo $ARIMA(0,1,0)(0,1,0)_4$ de ajuste à série do Tráfego Médio Diário na A2.

Utilizando as funções *detectAO()* e *detectIO()* para o modelo $ARIMA(0,1,0)(0,1,0)_4$ obtido anteriormente, é detetado um *outlier* do tipo IO na observação 10, correspondente ao 2º trimestre de 2009, sendo significativo uma vez que $|\lambda_1| = 3.626729 > z_{0.975} = 1.96$. É obtido um novo modelo $ARIMA(0,1,0)(0,1,0)_4$, sem a influência do *outlier* do tipo IO na observação 10, com um valor de $AIC = 629.02$, inferior ao AIC do modelo anterior.

Procedendo mais uma vez à análise residual do modelo, no gráfico da Figura 4.67 estão representados os resíduos padronizados onde se pode observar que os resíduos variam em torno de 0, e já não se verifica a existência observações discrepantes.




Figura 4.67: Resíduos Padronizados do modelo $ARIMA(0,1,0)(0,1,0)_4$ sem efeito do *outlier* detetado.

Depois da observação do gráfico dos resíduos, obtiveram-se os seguintes resultados para as hipóteses de autocorrelação e normalidade residual.

Teste de Autocorrelação de *Box-Ljung*:

- ❖ *valor* – $p = 0.1537$: Não se rejeita a hipótese nula, logo não existe autocorrelação entre os resíduos.

Teste de Normalidade de *Shapiro-Wilk*:

- ❖ $\text{valor} - p = 0.4844$: Não se rejeita a hipótese nula, logo os resíduos seguem aproximadamente uma distribuição Normal.

Pode-se então concluir que a série temporal em análise aparenta ser bem modelada pelo modelo $ARIMA(0,1,0)(0,1,0)_4$ sem influencia do *outlier* detetado. Na Figura 4.68 encontra-se representado o gráfico do modelo ajustado e o gráfico da série original.




Figura 4.68: Comparação entre a série do Tráfego Médio Diário na A2 e o modelo ajustado.

Previsão

Após realizado o diagnóstico dos resíduos, onde todas as hipóteses foram verificadas pode proceder-se à previsão até 2020.




Figura 4.69: Previsão do Tráfego Médio Diário na A2, de 2018 e 2020.

Prevê-se que o tráfego médio diário na A2 continue a crescer até 2020, tal como se pode verificar no gráfico da Figura 4.69, e que atinja nesse ano um valor máximo de cerca de 23 mil veículos/dia no 3º trimestre (Tabela E.1 do E). Estima-se que nos próximos anos se atinjam os valores mais elevados registados desde 2007. Sendo o objetivo contribuir para a redução da utilização do transporte individual como principal meio de deslocação, este ritmo de crescimento não será um cenário adequado ao objetivo que se pretende atingir, pelo que será necessário tomar medidas que possam prevenir esta situação.

4.5.2. Tráfego Médio Diário na Ponte Internacional do Guadiana

Análise Descritiva




Figura 4.70: Tráfego Médio Diário na Ponte Internacional do Guadiana: (a) Observações trimestrais; (b) Observações anuais.

Pela Figura 4.70, verifica-se que o Tráfego Médio Diário na Ponte Internacional do Guadiana teve um comportamento decrescente no seu valor médio anual entre 2008 e 2014, em cerca de 7 mil veículos/dia. Após 2014, o tráfego médio diário começou a crescer até 2017, no entanto ainda não voltou a atingir os valores que se observavam em 2008. O menor valor anual foi registado em 2014, um tráfego médio diário de cerca de 6 mil veículos/dia.

Especificação do Modelo

Teste de estacionariedade de *Dickey-Fuller*:

- ❖ $\text{valor} - p = 0.6823$: Não se rejeita a hipótese nula de não estacionariedade da série temporal, sendo necessário aplicar uma diferença não sazonal, $d = 1$, para tornar a série estacionária.

O gráfico da Figura 4.71 mostra que, após aplicar a diferenciação, a série temporal já se encontra estacionária tanto na média como na variância, sendo necessário remover a sazonalidade da série, aplicando uma diferença sazonal, $D = 1$.




Figura 4.71: Diferenciação da série do Tráfego Médio Diário na Ponte Internacional do Guadiana.

Para determinação dos restantes parâmetros do modelo, serão analisados os gráficos da ACF e PACF da série livre de tendência e sazonalidade, representados na Figura 4.71.




Figura 4.72: Função de Autocorrelação (a) e Autocorrelação Parcial (b) da série do Tráfego Médio Diário na Ponte Internacional do Guadiana.

O pico significativo no *lag* 4 na ACF sugere um modelo com uma componente MA sazonal de ordem 1, $Q = 1$, enquanto que o pico significativo no *lag* 4 da PACF sugere uma componente AR sazonal também de ordem 1, $P = 1$. Temos então dois possíveis modelos de estimação:

- ✓ $ARIMA(0,1,0)(0,1,1)_4$ com um $AIC = 652.30$
- ✓ $ARIMA(0,1,0)(1,1,0)_4$ com um $AIC = 654.74$

Tendo em conta o valor do AIC, é seleccionado o modelo $ARIMA(0,1,0)(0,1,1)_4$, sendo este o melhor modelo de ajustamento aos dados em questão.

Diagnóstico do Modelo




Figura 4.73: Resíduos Padronizados do modelo $ARIMA(0,1,0)(0,1,1)_4$ de ajuste à série do Tráfego Médio Diário na Ponte Internacional do Guadiana.

No gráfico da Figura 4.73 estão representados os resíduos padronizados onde se pode observar que os resíduos variam em torno de 0. No entanto será vantajoso mais uma vez investigar a existência de *outliers*, pois a observação relativa ao 2º trimestre de 2013 apresenta um valor residual mais elevado.

Utilizando as funções *detectAO()* e *detectIO()* para o modelo $ARIMA(0,1,0)(0,1,1)_4$ obtido anteriormente, é detetado um *outlier* do tipo IO na observação 26, correspondente ao 2º trimestre de 2013, sendo significativo uma vez que $|\lambda_1| = 3.264035 > z_{0.975} = 1.96$. É obtido um novo modelo $ARIMA(0,1,0)(0,1,1)_4$, sem a influência do *outlier* do tipo IO na observação 26, com um valor de $AIC = 652.23$, inferior ao AIC do modelo anterior.

Procedendo mais uma vez à análise residual do modelo, no gráfico da Figura 4.74 estão representados os resíduos padronizados onde se pode observar que os resíduos variam em torno de 0, e já não se verifica a existência observações discrepantes.




Figura 4.74: Resíduos Padronizados do modelo $ARIMA(0,1,0)(0,1,1)_4$ sem efeito do *outlier* detetado.

Depois da observação do gráfico dos resíduos, obtiveram-se os seguintes resultados para as hipóteses de autocorrelação e normalidade residual.

Teste de Autocorrelação de *Box-Ljung*:

- ❖ *valor – p* = 0.7862: Não se rejeita a hipótese nula, logo não existe autocorrelação entre os resíduos.

Teste de Normalidade de *Shapiro-Wilk*:

- ❖ *valor – p* = 0.5087: Não se rejeita a hipótese nula, logo os resíduos seguem aproximadamente uma distribuição Normal.

Pode-se então concluir que a série temporal em análise aparenta ser bem modelada pelo modelo $ARIMA(0,1,0)(0,1,1)_4$, sem influência do *outlier* detetado. Na Figura 4.75 encontra-se representado o gráfico do modelo ajustado e o gráfico da série original.




Figura 4.75: Comparação entre a série do Tráfego Médio Diário na Ponte Internacional do Guadiana e o modelo ajustado.

Previsão

Após realizado o diagnóstico dos resíduos, onde se verificou que o modelo $ARIMA(0,1,0)(0,1,1)_4$ é adequado aos dados da série do movimento de passageiros nas ligações internacionais, pode proceder-se à previsão até 2020.

Prevê-se que o TMD na Ponte Internacional do Guadiana sofra um ligeiro decréscimo no 3º trimestre a partir de 2018 e que mantenha um comportamento aproximadamente constante a partir daí. Esta previsão tem uma precisão um pouco baixa pelo que os seus valores deverão ser utilizados cuidadosamente, como se verifica, até 2013 o comportamento da série era bastante diferente dos valores que se registaram mais recentemente, o que se faz refletir no grau de precisão dos valores previstos. Os valores da previsão encontram-se na Tabela E.2 do Apêndice E.




Figura 4.76: Previsão do Tráfego Médio Diário na Ponte Internacional do Guadiana, de 2018 e 2020.

4.5.3. Tráfego Médio Diário na Autoestrada A22

Análise Descritiva

Pela Figura 4.77, verifica-se que o Tráfego Médio Diário na A22 teve um comportamento decrescente no seu valor médio anual entre 2007 e 2012, onde o decréscimo mais acentuado se deu entre o ano de 2011 e 2012 em cerca de 7 mil veículos/dia. Após 2014 o tráfego médio diário começou a crescer até 2017, no entanto ainda não voltou a atingir os valores que se observavam em 2008. O menor valor anual foi registado em 2014, um tráfego médio diário de cerca de 6 mil veículos/dia.

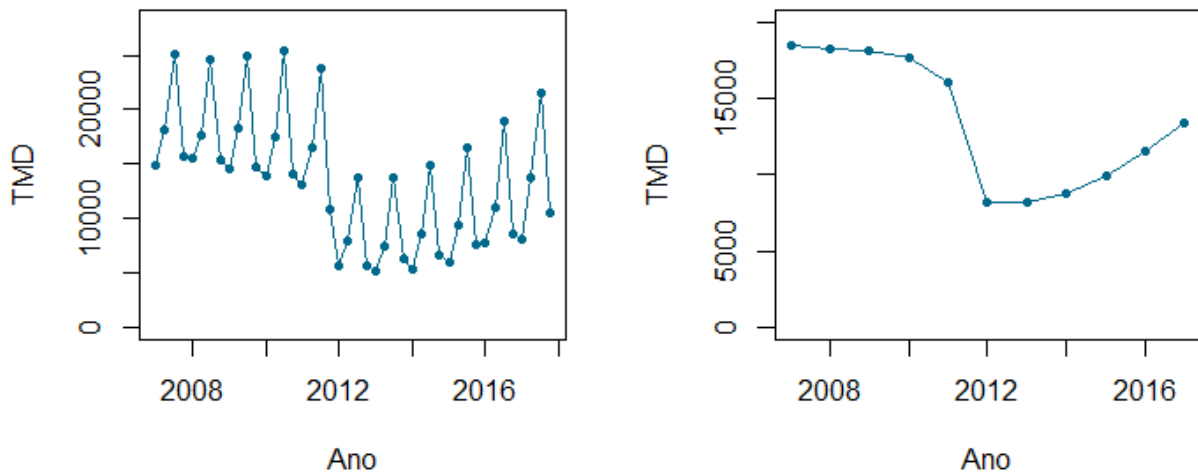


Figura 4.77: Tráfego Médio Diário na A22: (a) Observações trimestrais; (b) Observações anuais.

Especificação do Modelo

Uma vez que os dados trimestrais de 2007 a 2011 apresentam um padrão diferente dos restantes anos, optou-se por retirar estas observações para efeitos de estimação do modelo, para impedir que as mesmas influenciem de forma errada os valores de previsão.

Teste de estacionariedade de *Dickey-Fuller*:

- ❖ *valor - p* = 0.9571: Não se rejeita a hipótese nula de não estacionariedade da série temporal, sendo necessário aplicar uma diferença não sazonal, $d = 1$, para tornar a série estacionária.

O gráfico da Figura 4.78 mostra que, após aplicar a diferenciação, a série temporal já se encontra estacionária tanto na média como na variância, sendo necessário remover a sazonalidade da série, aplicando uma diferença sazonal, $D = 1$.




Figura 4.78: Diferenciação da série do Tráfego Médio Diário na A22.

Para determinação dos restantes parâmetros do modelo, serão analisados os gráficos da ACF e PACF da série livre de tendência e sazonalidade, representados na Figura 4.79.




Figura 4.79: Função de Autocorrelação (a) e Autocorrelação Parcial (b) da série do Tráfego Médio Diário na A22.

Uma vez que o pico significativo no *lag* 2 na PACF não está acompanhado de um pico significativo no *lag* 1, este deverá ser ignorado pelo que se considera o seguinte modelo:

✓ $ARIMA(0,1,0)(0,1,0)_4$ com um $AIC = 310.34$

Diagnóstico do Modelo

No gráfico da Figura 4.80 estão representados os resíduos padronizados onde se pode observar que os resíduos variam em torno de 0. No entanto será vantajoso mais uma vez investigar a existência de *outliers*, pois a observação relativa ao 2º trimestre de 2017 apresenta um valor residual mais elevado.




Figura 4.80: Resíduos Padronizados do modelo $ARIMA(0,1,0)(0,1,0)_4$ de ajuste à série do Tráfego Médio Diário na A22.

Utilizando as funções *detectAO()* e *detectIO()* para o modelo $ARIMA(0,1,0)(0,1,0)_4$ obtido anteriormente, é detetado um *outlier* do tipo IO na observação 22, correspondente ao 2º trimestre de 2017, sendo significativo uma vez que $|\lambda_1| = 3.75357 > z_{0.975} = 1.96$. É obtido um novo modelo $ARIMA(0,1,0)(0,1,0)_4$, sem a influência do *outlier* do tipo IO na observação 22, com um valor de $AIC = 306.62$, inferior ao AIC do modelo anterior.

Procedendo mais uma vez à análise residual do modelo, no gráfico da Figura 4.80 estão representados os resíduos padronizados onde se pode observar que os resíduos variam em torno de 0, e já não se verifica a existência observações discrepantes.




Figura 4.81: Resíduos Padronizados do modelo $ARIMA(0,1,0)(0,1,0)_4$ sem efeito do *outlier* detetado.

Depois da observação do gráfico dos resíduos, obtiveram-se os seguintes resultados para as hipóteses de autocorrelação e normalidade residual.

Teste de Autocorrelação de *Box-Ljung*:

- ❖ *valor – p* = 0.7272: Não se rejeita a hipótese nula, logo não existe autocorrelação entre os resíduos.

Teste de Normalidade de *Shapiro-Wilk*:

- ❖ *valor – p* = 0.6226: Não se rejeita a hipótese nula, logo os resíduos seguem aproximadamente uma distribuição Normal.

Pode-se então concluir que a série temporal em análise aparenta ser bem modelada pelo modelo $ARIMA(0,1,0)(0,1,0)_4$, sem influência do *outlier* detetado. Na Figura 4.82 encontra-se representado o gráfico do modelo ajustado e o gráfico da série original.




Figura 4.82: Comparação entre a série do Tráfego Médio Diário na A22 e o modelo ajustado.

Previsão

Após realizado o diagnóstico dos resíduos, onde se verificou que o modelo $ARIMA(0,1,0)(0,1,0)_4$ é adequado aos dados da série do movimento de passageiros nas ligações internacionais, pode proceder-se à previsão até 2020.




Figura 4.83: Previsão do Tráfego Médio Diário na A22, de 2018 e 2020.

Prevê-se que o TMD na A22 mantenha o seu crescimento até 2020, atingindo os valores que se registavam em 2007. Mais uma vez, este comportamento não é positivo uma vez que o objetivo consiste em fazer diminuir a utilização do transporte individual como principal meio de deslocação. A previsão encontra-se na Tabela E.3 do Apêndice E.

4.6. A Bicicleta como Modo de Transporte Hipocarbónico e Saudável

Os dados fornecidos pela AMAL, recolhidos pela aplicação móvel Strava (*app* Strava), apenas têm registos relativos aos anos de 2013 a 2016, onde se distinguem as viagens *Commute*⁷ das viagens *Recreative*⁸. Neste caso não será realizada uma previsão dos valores futuros uma vez que apenas se dispõe de informação relativa a quatro anos, o que não iria resultar numa previsão robusta. Para além disso, a distinção entre viagens *Commute* e *Recreative* poderá não ser a mais exata para a região, uma vez que é estabelecida por algoritmos que detetam a recorrência de cada percurso, admitindo que um percurso que é realizado pelo mesmo utilizador de forma repetida é considerado *Commute*, não sendo o utilizador da aplicação a definir que tipo de atividade irá fazer.

A Strava Metro recolhe dados de atividades de bicicleta através de dados de GPS obtidos pela *app* Strava, fazendo parcerias com departamentos de transporte e de planeamento urbano com o objetivo de melhorar as infraestruturas para ciclistas e pedestres [38]. Os dados recolhidos são bastante detalhados havendo informação anual, mensal, diária e ainda horária, que permitem uma análise profunda da

⁷ Deslocações pendulares, de casa para o trabalho ou de casa para o local de estudo.

⁸ Deslocações para efeitos de lazer.

atividade dos ciclistas. Serão analisados os dados de Origem/Destino que permitem entender os pontos inicial e final de cada atividade, por região.

Por observação do gráfico da Figura 4.84 verifica-se que a bicicleta é mais utilizada para efeitos de lazer (*Recreative*) do que para viagens pendulares (*Commute*).




Figura 4.84: Número de deslocações de bicicleta, registadas pela *app* Strava, em toda a região do Algarve, com observações trimestrais de 2013 até 2016.

Verifica-se também uma tendência de aumento do número de deslocações de bicicleta ao longo dos anos. No entanto, sendo estes registos relativos apenas aos utilizadores da *app* Strava, este aumento está circunscrito à evolução do mercado de telemóveis, com um número crescente de utilizadores com *smartphone*, o que poderá levar também a que hajam mais pessoas com a *app* instalada, e por sua vez um maior número de registos de deslocações de bicicleta. Por este mesmo motivo, serão analisadas as deslocações dos utilizadores da bicicleta para o ano de 2016 de uma forma mais detalhada, uma vez que é o ano que está mais próximo da situação atual de referência.

Em 2016, o número total de viagens de bicicleta registado pela *app* foi de 123273 registos. Destas viagens apenas 21% corresponde às viagens classificadas como *Commute* enquanto que 79% corresponde às viagens para efeitos recreativos. No gráfico da Figura 4.85, encontra-se o número de viagens diárias registadas em 2016, de onde se podem observar alguns padrões. Como é de esperar, as deslocações pendulares (*Commute*) não aparentam sofrer grandes alterações ao longo do ano, no entanto, tanto nos primeiros dias do ano como nos últimos, os valores registados são um pouco inferiores aos restantes, tal como é visível no gráfico da Figura 4.86. Como é natural, nos meses de inverno existe uma quebra nas deslocações em bicicleta, pois muitas das vezes devido às temperaturas que se podem registar, as pessoas optam por um modo de deslocação mais confortável para se deslocarem para o trabalho, face às condições atmosféricas.

Relativamente às viagens de bicicleta para efeitos de lazer (*Recreative*), o registo diário mais elevado observou-se no 67º dia do ano (751 viagens), que corresponde ao dia 7 de março de 2016. Sendo a média diária cerca de 257 viagens por dia, verifica-se também que os dois dias anteriores também apresentam valores muito elevados (581 e 569 viagens). Estes valores discrepantes podem ter ocorrido devido à

existência de um grande evento de BTT que ocorre no Algarve todos os anos no mês de março, o evento *Algarve Bike Challenge* ⁹, e que no ano de 2016 ocorreu de 4 a 6 de março, na cidade de Tavira.

Em ambos os gráficos, e ainda relativamente às viagens *Recreative*, verifica-se que os valores mais elevados encontram-se nos meses de Verão, principalmente no mês de agosto, onde as condições ambientais apelam para a prática de exercício físico e para a utilização deste modo de deslocação mais sustentável.




Figura 4.85: Número de deslocações de bicicleta, registadas pela *app* Strava diariamente em 2016, em toda a região do Algarve.




Figura 4.86: Número de deslocações de bicicleta, registadas pela *app* Strava mensalmente em 2016, em toda a região do Algarve.

⁹ Informação disponível em: <http://www.algarvebikechallenge.com/pt/>

No gráfico da Figura 4.87, encontra-se representada a média de deslocações de bicicleta, em cada hora do dia, na região do Algarve, para todos os meses do ano. Verifica-se que, ao longo do dia, a utilização da bicicleta para viagens *Commute* tem o maior pico entre as 7h e as 10h durante todos os meses do ano, o que seria de esperar pois diz respeito à altura do dia correspondente às deslocações de casa para o trabalho em Portugal. Nos meses de Verão, entre junho e setembro, verifica-se ainda a existência de um pico um pouco mais suave entre as 17h e as 19h, o que também é de esperar uma vez que diz respeito à altura do dia correspondente às deslocações do trabalho para casa e, como os dias são mais longos, as pessoas aproveitam para utilizar a bicicleta como meio de deslocação.

Verifica-se que a maioria das deslocações diárias registadas pela *app* são para efeitos de lazer, sendo em agosto onde se observa o maior número de deslocações, às 7h. O pico nos meses de julho e agosto regista-se às 7h por estes serem meses de verão, onde se faz sentir uma temperatura mais elevada, em que as pessoas aproveitam o início da manhã para fazer desporto. Nos meses de janeiro, fevereiro e dezembro observa-se uma deslocação deste pico para as 9h, por estes serem os meses mais frios.

Mais uma vez se observa que, depois de agosto, o mês de março apresenta o maior número diário de deslocações de bicicleta para efeitos de lazer, tal como verificado.

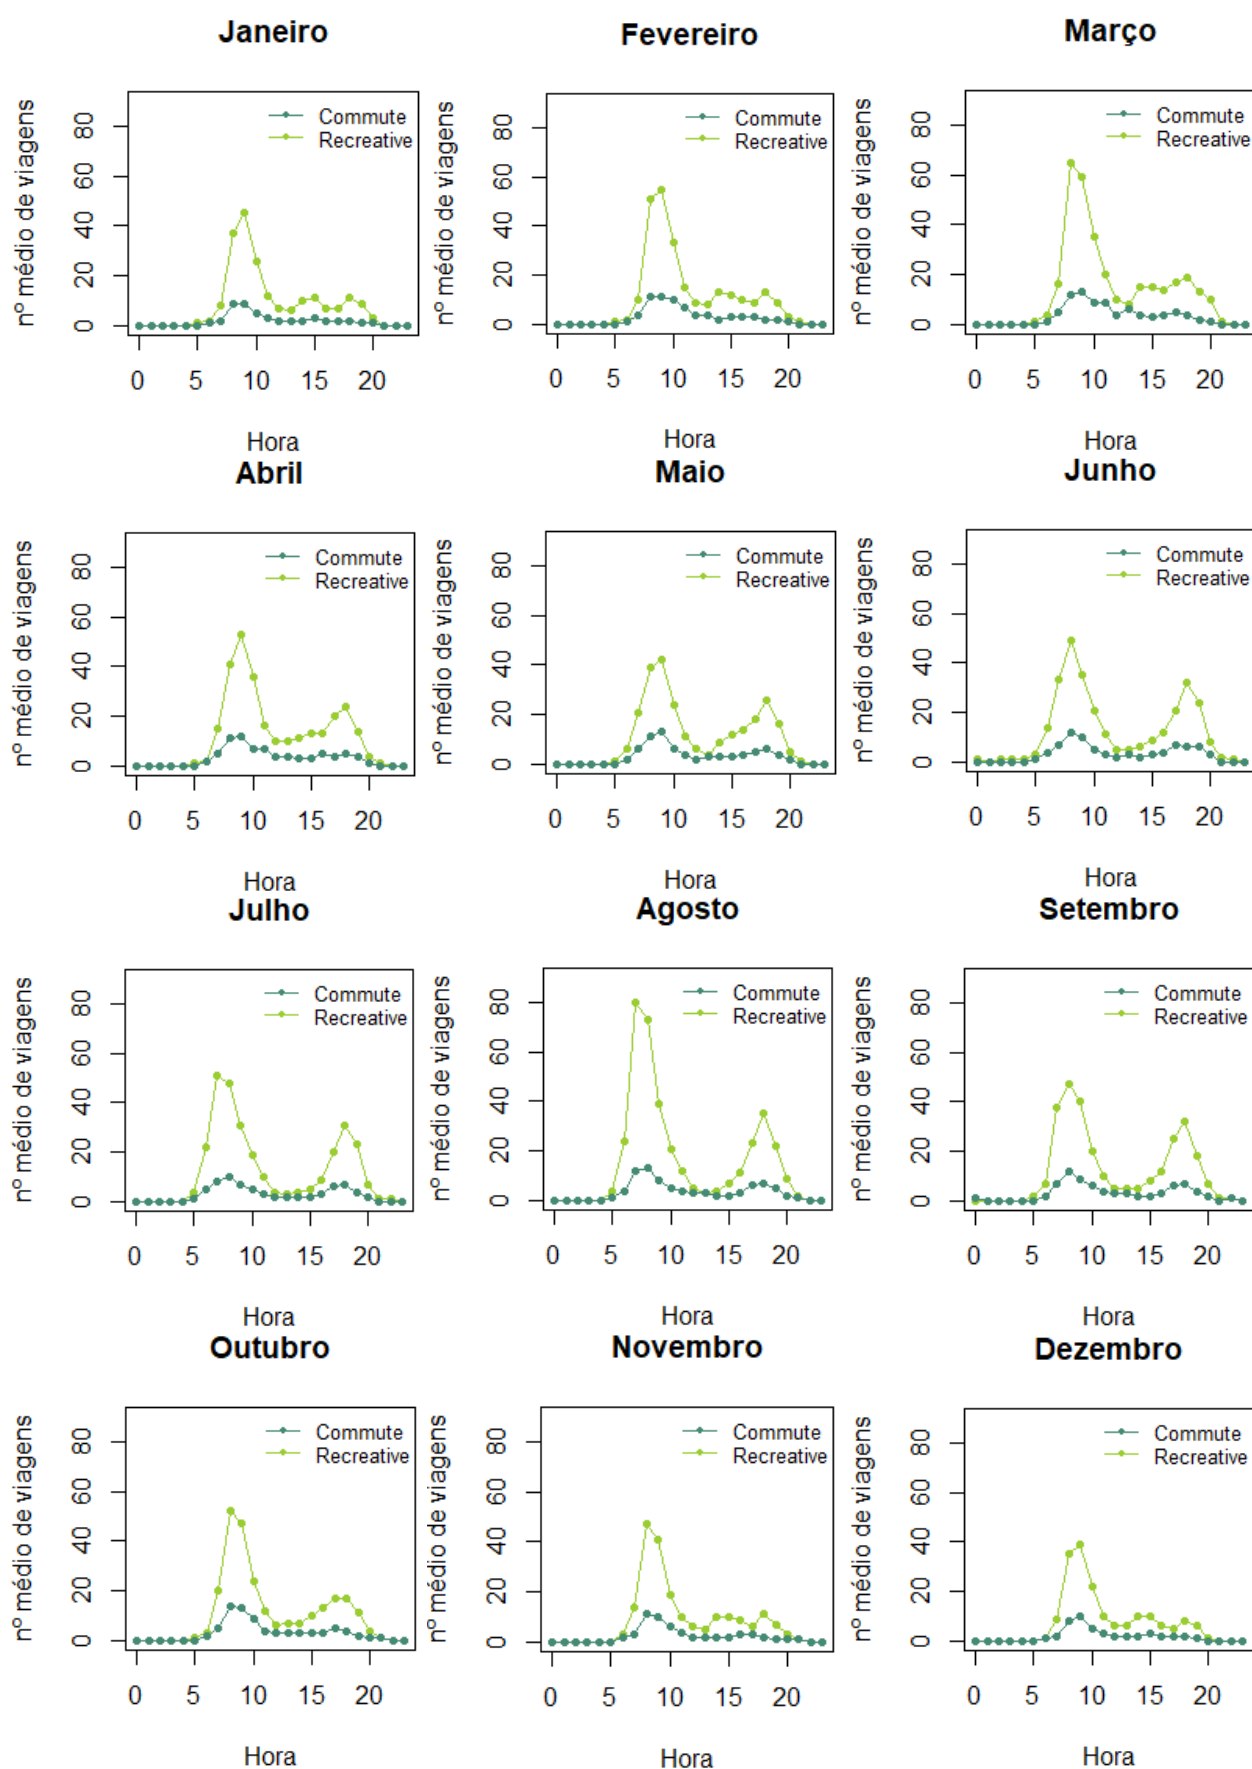


Figura 4.87: Número médio de deslocações de bicicleta, por hora, em toda a região do Algarve, registadas pela *app* Strava.

5. Conclusão e Recomendações

A previsão do número de passageiros que utiliza determinado modo de transporte assume uma elevada importância no planeamento da mobilidade, pois permite que as entidades responsáveis definam estratégias prévias que poderão ser essenciais para garantir uma gestão mais eficiente do sistema de transportes na região.

Pelo facto da procura relativa a cada modo de transporte depender de muitos fatores externos, a previsão deste tipo de séries temporais torna-se uma tarefa bastante difícil e complexa.

Para além disso, muitas foram as condicionantes do estudo. O principal problema centrou-se no comprimento das séries temporais, onde o número de observações de cada uma delas nunca foi superior a 44. Por este motivo, a informação que se consegue retirar dos dados para estimar o modelo não é muito vasta, tendo levado, muitas das vezes, à obtenção de previsões com um grande grau de incerteza associado, visível na grande amplitude dos limites de previsão. Também devido a esta condicionante, não se procedeu à avaliação da previsão, uma vez que seria necessário retirar, pelo menos, os dois últimos anos de cada uma das séries para testar se o modelo estimado produzia boas previsões. No entanto este passo iria tornar as séries temporais ainda mais curtas e iria retirar informação útil para a escolha de um modelo adequado aos dados.

Para investigações futuras seria interessante integrar nos modelos estimados outro tipo de variáveis, tais como variáveis socioeconómicas, turismo, entre outros. Seria também interessante procurar modificar o comportamento futuro das séries através do ajustamento de variáveis controláveis, como por exemplo, através de dados relativos à capacidade máxima de cada um dos modos de transporte.

Tal como referido no capítulo introdutório, o desenvolvimento deste projeto pretendeu dar resposta às seguintes questões:

- ✓ Que padrões de mobilidade se observam nos diversos modos de transporte na região do Algarve?
- ✓ Quais as tendências que podem ser esperadas nos próximos anos?
- ✓ De acordo com os modelos de previsão estimados e respetivos resultados, que recomendações podem ser úteis às entidades responsáveis pelo planeamento da mobilidade e transportes, para melhorar a acessibilidade e mobilidade na região?

Na análise de cada um dos modos de transporte, constatou-se ser sempre visível a existência de sazonalidade nas diversas séries temporais, o que justifica a opção dos modelos de previsão utilizados.

Transporte Aéreo

No transporte aéreo, verificou-se um aumento do movimento de passageiros tanto nos voos internacionais registado no Aeroporto Internacional de Faro como nas viagens realizadas entre Faro e outros aeroportos nacionais. A forte sazonalidade é também característica da procura deste meio de transporte, onde os valores mais elevados do número de passageiros são registados no terceiro trimestre.

Prevê-se que o movimento de passageiros no Aeroporto Internacional de Faro continue a crescer continuamente até 2020. Estando o aeroporto localizado numa área de paisagem protegida, este apresenta limitações de crescimento, sendo difícil expandir a sua capacidade. Por este mesmo motivo,

outras medidas deverão ser tomadas para contornar o constante aumento do número de passageiros, de forma a garantir a qualidade do serviço e o bem-estar de quem o utiliza. Este facto pode passar por estudar uma solução que passe por rentabilizar o Aeroporto em Beja com infraestruturas complementares de ligação eficazes até ao Aeroporto Internacional de Faro [39] (por exemplo, modo ferroviário).

Transporte Ferroviário

No transporte ferroviário, observou-se um decréscimo continuado do número de passageiros que utilizavam o serviço regional do transporte ferroviário até 2012, tendo-se invertido a tendência a partir desse ano, onde o número de passageiros que utilizam este serviço começou a aumentar ligeiramente. Relativamente ao serviço de longo curso, observou-se uma ligeira diminuição na utilização desde serviço entre 2009 e 2012, tendo começado também a crescer a partir desse ano.

Prevê-se que o número de passageiros que utiliza o serviço regional e o serviço de longo curso do transporte ferroviário continue a crescer até 2020, pelo que, possivelmente, serão necessárias intervenções a nível de infraestruturas para que este transporte consiga acompanhar o contínuo crescimento da procura e da exigência de qualidade do serviço que decorrem do crescimento do turismo.. Esta tendência de evolução é bastante positiva para os objetivos de mobilidade sustentável da região uma vez que, por ser uma alternativa ao transporte individual, o aumento da utilização deste transporte poderá levar à inversão dos padrões atuais, com predominância do transporte individual.

Transporte Fluvial/Marítimo

No transporte fluvial, o movimento de passageiros na carreira do Guadiana apresentou uma acentuada diminuição na sua utilização entre 2007 e 2013, tendo voltado a crescer a partir deste mesmo ano. Prevê-se que o número de passageiros que utiliza a carreira do Guadiana continue a crescer até 2020, e que esse número se volte a aproximar dos valores registados em 2008. Posto isto, esta carreira deverá ter capacidade de acompanhar o crescimento da procura uma vez que já atingiu os valores que se prevê, em anos anteriores.

O número de passageiros nas carreiras da Ria Formosa tem vindo a crescer ao longo dos anos, acompanhando o aumento do turismo na região, necessitando de uma atenção acrescida. Seria interessante, num projeto futuro, realizar um estudo mais aprofundado sobre o transporte fluvial, designadamente devido ao interesse em viabilizar alternativas aos barcos a diesel utilizados atualmente nas viagens, com redução do impacto ambiental (por exemplo, com recurso a barcos solares). A Ria Formosa é uma área protegida pelo que deverão ser tomadas medidas de forma a preservar este Parque Natural designadamente para minimizar a pegada carbónica do transporte, fato que pode exigir uma maior regulamentação e regulação.

Transporte Coletivo Rodoviário

No transporte coletivo rodoviário, nas ligações urbanas, observou-se uma acentuada diminuição na sua utilização entre 2011 e 2013, mantendo um comportamento aproximadamente constante a partir de 2013. O mesmo padrão se verificou nas ligações inter-urbanas, assistindo-se a uma diminuição da utilização do transporte coletivo rodoviário entre 2007 e 2014, mantendo a partir desse último ano uma procura aproximadamente constante e bastante inferior à que se registava em 2007. Esta série temporal apresenta um comportamento diferente das séries dos restantes transportes do Algarve, uma vez que os valores mais baixos são sempre registados no 3º trimestre, por ser utilizada maioritariamente por estudantes e pelos residentes locais.

A utilização das carreiras inter-regionais teve uma utilização crescente a partir de 2013, enquanto que o movimento de passageiros nas ligações internacionais teve uma variação positiva entre 2007 e 2015, começando a diminuir a partir desse último ano.

Prevê-se que o número de passageiros do transporte coletivo rodoviário que utiliza as ligações urbanas diminua ligeiramente até 2020. Pelo contrário, prevê-se que o número de passageiros que utiliza as ligações inter-regionais do referido modo de transporte continue a crescer até 2020, e se mantenha aproximadamente constante nas ligações inter-urbanas e internacionais.

Este modo de transporte é uma das mais importantes alternativas atuais ao transporte individual no Algarve. No entanto são necessárias medidas de melhoria da qualidade do serviço prestado uma vez que, atualmente, ainda são poucas as pessoas que optam pela utilização deste modo de transporte e, por outro lado, não se observam padrões que levem a crer que esta tendência venha a ser alterada num futuro próximo. Para tentar perceber o porquê da fraca aderência ao transporte coletivo rodoviário, seria vantajoso realizar algum tipo de inquéritos de satisfação deste transporte, que possam avaliar em que aspetos este poderá ser melhorado de forma a aumentar atratividade do mesmo e, assim, a procura de passageiros por este modo de transporte. Alternativas relacionadas a novos trajetos realizados pelos autocarros ou uma maior frequência dos mesmos, poderá trazer um aumento na sua utilização.

Transporte Rodoviário – Rede Rodoviária Principal

O TMD na A2 sofreu um grande decréscimo no seu valor médio anual entre 2009 e 2012, tendo começado a crescer gradualmente a partir de 2013, voltando a atingir em 2017 valores próximos aos registados em 2009.

Prevê-se que o TMD na A2 continue a crescer até 2020 e que nos próximos anos se atinjam os valores mais elevados registados desde 2007. Sendo o objetivo fazer diminuir a utilização do transporte individual como principal meio de deslocação, este ritmo de crescimento não será um cenário adequado ao objetivo pretendido, pelo que será necessário tomar medidas que possam prevenir esta situação.

O TMD na Ponte Internacional do Guadiana teve um comportamento decrescente no seu valor médio anual entre 2008 e 2014. Após 2014 o TMD começou a crescer, no entanto esse crescimento não foi suficiente para atingir os valores que se observavam em 2008.

Prevê-se que o tráfego médio diário na Ponte Internacional do Guadiana sofra um ligeiro decréscimo nos valores do 3º trimestre a partir de 2018 e que tenha um comportamento aproximadamente constante nestes 3 anos. Esta previsão tem uma precisão um pouco baixa pelo que os seus valores deverão ser utilizados cuidadosamente, como se verifica, até 2013 o comportamento da série era bastante diferente dos valores que se registaram mais recentemente, o que se faz refletir no grau de precisão dos valores previstos.

O TMD na A22 teve um comportamento aproximadamente constante até 2011, tendo sofrido um decréscimo repentino em 2012. A partir desse ano tem vindo a crescer gradualmente e prevê-se que em 2020 ultrapasse os valores que se atingiam em 2007. Esta previsão foi feita, através de um modelo estimado apenas para 24 observações pelo que os resultados não são muito robustos.

Numa análise global das previsões até 2020, não se prevê grandes decréscimos na utilização do transporte individual nem aumentos na utilização do transporte coletivo rodoviário, sendo necessário tomar medidas para que este comportamento não se venha a observar.

Em contrapartida, espera-se que nos próximos três anos, a procura do transporte ferroviário continue a crescer, o que é um aspeto positivo a considerar no caminho para uma mobilidade sustentável. O aumento esperado da procura terá de ser acompanhado por um maior investimento na qualidade do serviço de transporte prestado aos passageiros, promovendo também a intermodalidade (por exemplo, articulação do modo de transporte aéreo com o transporte ferroviário). Quanto à bicicleta como modo hipocarbónico sustentável, considera-se que, com os investimentos previstos no PAMUS da região do Algarve, possa vir a constituir uma alternativa para a transferência de deslocações dos modos motorizados para a bicicleta.

Para que seja possível, no futuro, inverter a repartição modal e promover a descarbonização da mobilidade (transferindo deslocações dos veículos de motorização convencional para modos de transporte mais sustentáveis, em alternativa), é necessário investir num transporte coletivo mais eficiente que satisfaça as necessidades de mobilidade/acessibilidade diárias da população e turistas, o que pode passar pela promoção da bicicleta, mobilidade elétrica e novos serviços de mobilidade. Por outro lado, será de interesse promover a articulação entre os vários modos de transporte, eliminando barreiras, visando um sistema de transporte multimodal que sirva as necessidades de mobilidade e acessibilidade de todos, incluindo as pessoas com mobilidade condicionada. É necessário também tomar medidas para a sensibilização e consciencialização das pessoas, visando a alteração de hábitos. O investimento em bicicletas municipais que possam ser utilizadas por qualquer pessoa que assim o pretenda, bem como melhorias nas infraestruturas que permitem a sua circulação segura, como a construção de novas ciclovias, poderão trazer benefícios sociais e ambientais no futuro. A este respeito, pode ser de interesse proceder à avaliação da eficiência da rede de bicicleta de Vilamoura, no município de Loulé já em funcionamento desde 2012¹⁰, e verificar a viabilidade de implementar uma rede semelhante em outros municípios do Algarve.

¹⁰ Informação disponível em: <http://www.inframoura.pt/pt/sistema>

6. Referências Bibliográficas

- [1] Akaike, H. (1974). *A new look at the statistical model identification*, IEEE Transactions on Automatic Control, 19 (6): 716–723, doi:10.1109/TAC.1974.1100705, MR 0423716.
- [2] APA (2017), Relatório de Estado do Ambiente [Online]. Disponível em: <https://rea.apambiente.pt/content/pegada-energ%C3%A9tica-e-carb%C3%B3nica-dos-transportes?language=pt-pt> [Consultado em Setembro de 2018].
- [3] AMAL (2017). *Plano de Ação para a Mobilidade Urbana Sustentável no Algarve*.
- [4] Arsenio, E. and Coelho, J. (2018), *The Role of Sustainable Urban Mobility Plans and ICT to Improve Public Space for Social Inclusion*, in Menezes, M. and Smaniotto, C. (Editors). Neighbourhood & City - Between digital and analogue perspectives, CyberParks Project. Series Culture and Territory (3), Lisbon: UL. 300 pages, ISBN 978-989-757-077-3.
- [5] Arsenio, E. and Ribeiro, P (2015). *The Economic Assessment of Health Benefits of Active Transport*, in Maria Attard , Yoram Shiftan (ed.) Sustainable Urban Transport (Transport and Sustainability, Volume 7) Emerald Group Publishing Limited, pp.1 – 22.
- [6] Arsenio, E.; Dias, J.V.; Lopes, S.A.; Pereira, H.I. (2018). *Assessing the market potential of electric bicycles and ICT for low carbon school travel: a case study in the smart city of Águeda*. European Transport Research Review 10:13. <https://doi.org/10.1007/s12544-017-0279-z>.
- [7] Box, G. E., & Cox, D. R. (1964). *An analysis of transformations*. Journal of the Royal Statistical Society.
- [8] Box, G. E., Jenkins, G. M. e Reinsel, G. (1994). *Time Series Analysis: Forecasting and Control*, 3rd Edition, Prentice-Hall.
- [9] Brockwell, P.J. e Davis, R.A. (2002). *Introduction to time Series and Forecasting*. 2nd Edition, Springer.
- [10] CCDR Algarve: Boletins Algarve Conjuntura [Online]. Disponível em: <https://www.ccdr-alg.pt/site/info/boletins-algarve-conjuntura> [Consultado de Outubro de 2017 a Abril de 2018].
- [11] Chan, K. e Ripley, B. (2012). *TSA: Time Series Analysis. R Package* [Online]. Disponível em: <http://CRAN.R-project.org/package=TSA> [Consultado em Março de 2018].
- [12] Comissão Europeia. *Alterações climáticas: de que se trata? - Uma introdução para os jovens*. Luxemburgo: Serviço das Publicações Oficiais das Comunidades Europeias, 2009 [Online]. Disponível em: http://europa.europa.eu/comm/external_relations/climate/alteracoes_climaticas_de_que_se_trata.pdf [Consultado em Agosto de 2018].
- [13] Cowpertwait P., Metcalfe A. (2009). *Introductory Time Series with R*. Springer New York.

- [14] Cryer, Jonathan D., e Kung-Sik Chan (2008). *Time Series Analysis With Applications in R*. 2nd Edition. Springer.
- [15] Diário da República, Decreto de Lei n.º 111/2015, Série I, 9 de Junho de 2015.
- [16] Dickey, D. A. e Fuller, W. A. (1979) *Distribution of the estimators for autoregressive time series with a unit root*. Journal of the American statistical association.
- [17] Ehlers, R. S. (2009). *Análise de Séries Temporais*. Universidade São Paulo.
- [18] Enders, W. (2008) *Applied econometric time series*. John Wiley & Sons, New York.
- [19] Ferreira, Pedro. (2016). *Análise de Séries Temporais em R: um curso introdutório*.
- [20] Hamilton, J. D. (1994). *Time series analysis.*, vol. 2. Princeton: Princeton university press.
- [21] Hyndman R. J. (2014). *Forecasting: Principles & Practice*. University of Western Australia.
- [22] Hyndman, R. J. (2016). *Forecast: Forecasting functions for time series and linear models*.
- [23] Hyndman, R. J. and Khandakar, Y. (2008). *Automatic time series forecasting: The forecast package for R*. In Journal of Statistical Software, Volume 27.
- [24] INE, I.P. (2012), *Censos 2011 - Resultados Definitivos, Região Algarve*. Instituto Nacional de Estatística, ISSN 0872-6493, ISBN 978-989-25-0183-3. Lisboa, Portugal.
- [25] Instituto Nacional de Estatística - Statistics Portugal [Online]. Disponível em: https://www.ine.pt/xportal/xmain?xpid=INE&xpgid=ine_indicadores&indOcorrCod=0008272&contexto=bd&selTab=tab2 [Consultado em Setembro de 2018].
- [26] Kwiatkowski D, Phillips PC, Schmidt P, Shin Y (1992). *Testing the null hypothesis of stationarity against the alternative of a unit root*. Journal of Econometrics.
- [27] Liu, L. and Chen, R. (2017). *A novel passenger flow prediction model using deep learning methods*. Transportation Research Part C, 84, 74-91
- [28] Ljung, G. M. e Box, G. E. P. (1978). *On a measure of a lack of fit in time series models*. Biometrika.
- [29] Loulé adapta: Áreas de Intervenção, Mobilidade [Online]. Disponível em: <http://www.louleadapta.pt/areas-de-intervencao/mobilidade> [Consultado em Setembro de 2018].
- [30] Makridakis, S., Wheelwright, S. C e Hyndman, R. J. (1998). *Forecasting Methods and Applications*. 3rd Edition, John Wiley & Sons, New York.
- [31] Morettin, Pedro A., Cléia M. C. Toloi (2006). *Análise de Séries Temporais*. 2ª Edição. Egar Blucher, São Paulo.
- [32] Murteira, B., Muller, D. e Turkman, K. (2000). *Análise de sucessões cronológicas*, McGrawHill.

- [33] PORDATA - Taxa de desemprego: total e por grupo etário (%) [Online]. Disponível em: [https://www.pordata.pt/Municipios/Taxa+de+desemprego+total+e+por+grupo+et%C3%A1rio+\(percentagem\)-859](https://www.pordata.pt/Municipios/Taxa+de+desemprego+total+e+por+grupo+et%C3%A1rio+(percentagem)-859) [Consultado em Julho de 2018].
- [34] Postal. “Transportes públicos colectivos são o grande problema do Algarve” (23 de Fevereiro de 2018) [Online]. Disponível em: <http://www.postal.pt/2018/02/transportes-publicos-colectivos-sao-grande-problema-do-algarve/> [Consultado em Abril de 2018].
- [35] R Core Team. R: A Language and Environment for Statistical Computing. R Foundation for Statistical Computing. Vienna, 2016.
- [36] Shapiro, S. S.; Wilk, M. B. (1965). *An analysis of variance test for normality (complete samples)*. Biometrika.
- [37] Shumway R.H. and Stoffer D.S., Time Series Analysis and Its Applications: With R Examples, 3rd ed. Springer Texts in Statistics, 2011.
- [38] STRAVA METRO: Better Data for Better Cities [Online]. Disponível em: <https://metro.strava.com/> [Consultado em Setembro de 2018].
- [39] Sul Informação. “Aeroporto de Beja pode servir Lisboa, Algarve e Extremadura espanhola” (23 de Julho de 2018) [Online]. Disponível em: <http://www.sulinformacao.pt/2018/07/aeroporto-de-beja-servir-lisboa-algarve-e-extremadura-espanhola/> [Consultado em Julho de 2018].
- [40] Sul Informação. “Projeto de eletrificação da Linha do Algarve vai ser apresentado em Faro” (3 de Abril de 2018) [Online]. Disponível em: <http://www.sulinformacao.pt/2018/04/projeto-de-eletrificacao-da-linha-do-algarve-vai-ser-apresentado-em-faro/> [Consultado em Junho de 2018].
- [41] Trapletti, A e Hornik, K. (2015). tseries: Time Series Analysis and Computational Finance. R Package [Online]. Disponível em: <https://cran.r-project.org/web/packages/tseries/tseries.pdf> [Consultado em Maio de 2018].
- [42] Wei, W. W. S. (2007). *Time Series Analysis: Univariate and Multivariate Methods*, 2nd Edition, Addison-Wesley Publishing Company, Redwood City, California.
- [43] Wikipedia, a enciclopédia livre: Aeroporto Internacional de Faro [Online]. Disponível em: https://pt.wikipedia.org/wiki/Aeroporto_Internacional_de_Faro [Consultado em Junho de 2018].

Apêndices

Apêndice A: Previsões das séries temporais do Transporte Aéreo

Tabela A.1: Valores obtidos da previsão trimestral do movimento de passageiros no Aeroporto Internacional de Faro, de 2018 a 2020.

	1º Trimestre	2º Trimestre	3º Trimestre	4º Trimestre
2018	952786	3016116	3711373	1526483
2019	1005583	3183248	3917032	1611070
2020	1061305	3359641	4134086	1700345

Tabela A.2: Valores da previsão trimestral do movimento de passageiros entre o Aeroporto Internacional de Faro e outros Aeroportos nacionais, de 2018 a 2020.

	1º Trimestre	2º Trimestre	3º Trimestre	4º Trimestre
2018	97271	125274	151009	104378
2019	96648	127841	162302	123274
2020	115474	144632	173391	132903

Apêndice B: Previsões das séries do Transporte Ferroviário

Tabela B.1: Valores da previsão trimestral do movimento de passageiros no Serviço Regional, de 2018 a 2020.

	1º Trimestre	2º Trimestre	3º Trimestre	4º Trimestre
2018	437058	501557	559995	457705
2019	456350	520848	579287	476997
2020	475642	540140	598578	496289

Tabela B.2: Valores da previsão trimestral do movimento de passageiros no Serviço de Longo Curso, de 2018 a 2020.

	1º Trimestre	2º Trimestre	3º Trimestre	4º Trimestre
2018	175847	249071	331856	202480
2019	197663	270349	353818	224218
2020	219251	292136	375537	245896

Apêndice C: Previsões das séries do Transporte Fluvial/Marítimo

Tabela C.1: Valores obtidos da previsão trimestral do movimento de passageiros nas carreiras do Guadiana, de 2018 a 2020.

	1º Trimestre	2º Trimestre	3º Trimestre	4º Trimestre
2018	18850	33732	66951	30864
2019	21316	36198	69417	33330
2020	23782	38664	71883	35796

Apêndice D: Previsões das séries do Transporte Coletivo Rodoviário

Tabela D.1: Valores obtidos da previsão trimestral do movimento de passageiros nas Ligações Urbanas, de 2018 a 2020.

	1º Trimestre	2º Trimestre	3º Trimestre	4º Trimestre
2018	1160069	1244323	1299309	1147956
2019	1153659	1232013	1289811	1133198
2020	1136929	1217068	1274015	1118993

Tabela D.2: Valores da previsão trimestral do movimento de passageiros nas Ligações Inter-Urbanas, de 2018 a 2020.

	1º Trimestre	2º Trimestre	3º Trimestre	4º Trimestre
2018	1498231	1493795	1213283	1443364
2019	1519265	1496234	1221256	1453417
2020	1522554	1507740	1230955	1461240

Tabela D.3: Valores da previsão trimestral do movimento de passageiros nas Ligações Inter-Regionais, de 2018 a 2020.

	1º Trimestre	2º Trimestre	3º Trimestre	4º Trimestre
2018	165445	225922	379740	207913
2019	184265	244742	398560	226733
2020	203084	263561	417379	245552

Tabela D.4: Valores da previsão trimestral do movimento de passageiros nas Ligações Internacionais, de 2018 a 2020.

	1º Trimestre	2º Trimestre	3º Trimestre	4º Trimestre
2018	3587	6301	11164	5123
2019	3454	6168	11031	4990
2020	3320	6034	10897	4856

Apêndice E: Previsões das séries do Transporte Rodoviário: Eixos Principais

Tabela E.1: Valores da previsão trimestral do tráfego médio diário na A2, de 2018 a 2020.

	1º Trimestre	2º Trimestre	3º Trimestre	4º Trimestre
2018	7600	11782	21112	9177
2019	8789	12971	22301	10366
2020	9978	14160	23490	11555

Tabela E.2: Valores da previsão trimestral do tráfego médio diário na Ponte Internacional do Guadiana, de 2018 a 2020.

	1º Trimestre	2º Trimestre	3º Trimestre	4º Trimestre
2018	6009	7854	12416	6268
2019	6148	7994	12556	6407
2020	6287	8133	12695	6547

Tabela E.3: Valores da previsão trimestral do movimento do tráfego médio diário na A22, de 2018 a 2020.

	1º Trimestre	2º Trimestre	3º Trimestre	4º Trimestre
2018	10038	14368	23471	12565
2019	12028	16358	25461	14555
2020	14018	18348	27451	16545